

**PERBANDINGAN KINERJA ARSITEKTUR *EFFICIENTNETV2B0*
DAN *XCEPTION* UNTUK KLASIFIKASI TUMBUHAN OBAT
BERDASARKAN CITRA DAUN**

Oleh

VIDYA SINTA BILLKIS

Skripsi

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

Pada

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



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

ABSTRAK

PERBANDINGAN KINERJA ARSITEKTUR *EFFICIENTNETV2B0* DAN *XCEPTION* UNTUK KLASIFIKASI TUMBUHAN OBAT BERDASARKAN CITRA DAUN

Oleh

VIDYA SINTA BILLKIS

Indonesia memiliki keanekaragaman hayati yang tinggi, termasuk tumbuhan obat yang secara tradisional dimanfaatkan untuk berbagai pengobatan. Namun, masyarakat masih mengalami kesulitan dalam mengenali jenis-jenis tumbuhan obat berdasarkan morfologi daun karena variasi bentuk yang tinggi. Penelitian ini bertujuan untuk mengklasifikasikan tumbuhan obat berdasarkan citra daun, serta membandingkan kinerja dua arsitektur *EfficientNetV2B0* dan *Xception*. *Dataset* yang digunakan terdiri dari 3000 citra daun tunggal dari 10 jenis tumbuhan obat yang dikategorikan dalam dua bentuk morfologi, yaitu jantung (*cordate*) dan bulat telur (*ovate*). Penelitian dilakukan melalui tahapan pengumpulan data, *preprocessing* (*resize*, normalisasi, dan pembagian data), *training* model menggunakan *transfer learning*, serta evaluasi kinerja model dengan menggunakan *confusion matrix*. Hasil menunjukkan bahwa arsitektur *EfficientNetV2B0* memiliki kinerja klasifikasi yang lebih tinggi dengan rata-rata akurasi sebesar 99.5%, dibandingkan dengan arsitektur *Xception* yang mencapai rata-rata akurasi 98.33%. Selain itu, *EfficientNetV2B0* juga menunjukkan waktu *training* yang lebih cepat. Kedua model tersebut kemudian diimplementasikan dalam bentuk aplikasi *web* dengan menggunakan *framework Streamlit* untuk memudahkan identifikasi tumbuhan obat secara praktis dan akurat. Penelitian ini diharapkan dapat memberikan kontribusi terhadap pengembangan teknologi identifikasi tumbuhan obat di Indonesia.

Kata kunci: klasifikasi citra, tumbuhan obat, *EfficientNetV2B0*, *Xception*.

ABSTRACT

PERFORMANCE COMPARISON OF EFFICIENTNETV2B0 AND XCEPTION ARCHITECTURE FOR MEDICINAL PLANT CLASSIFICATION BASE ON LEAF IMAGES

By

VIDYA SINTA BILLKIS

Indonesia has high biodiversity, including medicinal plants that are traditionally used for various treatments. However, people still have difficulty in recognizing the types of medicinal plants based on leaf morphology due to high variation in shape. This study aims to classify medicinal plants based on leaf images, while comparing the performance of two architectures EfficientNetV2B0 and Xception. The dataset used consists of 3000 single leaf images from 10 types of medicinal plants categorized into two morphological forms, namely heart (cordate) and ovate (ovate). The research was conducted through the stages of data collection, preprocessing (resize, normalization, and data division), model training using transfer learning, and model performance evaluation using confusion matrix. The results show that the EfficientNetV2B0 architecture has a higher classification performance with an average accuracy of 99.5%, compared to the Xception architecture which achieves an average accuracy of 98.33%. In addition, EfficientNetV2B0 also showed faster training time. Both models were then implemented in the form of web applications using the Streamlit framework to facilitate the identification of medicinal plants practically and accurately. This research is expected to contribute to the development of medicinal plant identification technology in Indonesia.

Keywords: image classification, medicinal plants, EfficientNetV2B0, Xception.

Judul Skripsi

: PERBANDINGAN KINERJA ARSITEKTUR
EFFICIENTNETV2B0 DAN XCEPTION
UNTUK KLASIFIKASI TUMBUHAN OBAT
BERDASARKAN CITRA DAUN

Nama Mahasiswa

: **Vidya Sinta Billkis**

Nomor Pokok Mahasiswa : **2117051029**

Program Studi

: **S1-Ilmu Komputer**

Fakultas

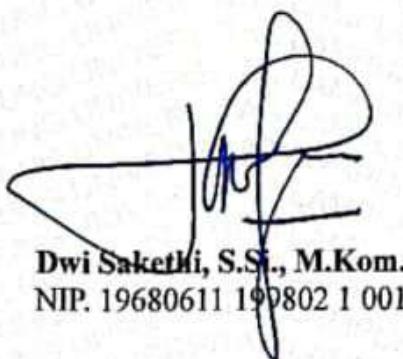
: **Matematika dan Ilmu Pengetahuan Alam**



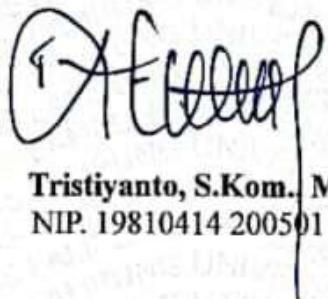
Yunda Heningtyas, M.Kom.
NIP. 19890108 201903 2 014

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

2. Mengetahui



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



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

MENGESAHKAN

1. Tim Penguji

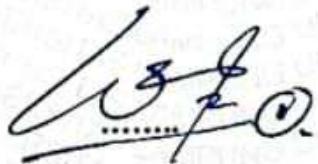
Ketua

: Yunda Heningtyas, M.Kom.



Sekretaris

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

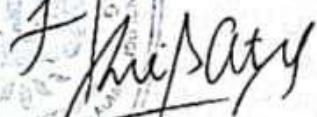


Penguji

Bukan Pembimbing : Tristiyanto, S.Kom., M.I.S., Ph.D.



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Heri Satria, S.Si., M.Si.

NIP. 19771001 200501 1 002

Tanggal Lulus Ujian Skripsi: 20 Juni 2025

PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : Vidya Sinta Billkis

NPM : 2117051029

Dengan ini menyatakan bahwa skripsi saya yang berjudul **“Perbandingan Kinerja Arsitektur EfficientNetV2B0 dan Xception untuk Klasifikasi Tumbuhan Obat Berdasarkan Citra Daun”** merupakan hasil karya saya sendiri dan bukan karya orang lain. Seluruh tulisan yang tertuang di skripsi ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Apabila di kemudian hari terbukti skripsi saya merupakan hasil jiplakan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan hukum yang berlaku.

Bandar Lampung, 28 Juli 2025



RIWAYAT HIDUP



Penulis dilahirkan di Bandar Lampung pada tanggal 6 Januari 2003 sebagai anak pertama dari 3 bersaudara, dari pasangan Bapak Veri Novianto dan Ibu Desi Apriani. Penulis menyelesaikan pendidikan formal pertama di Taman Kanak-kanak (TK) Kuntum Bandar Lampung pada tahun 2009, kemudian melanjutkan pendidikan Sekolah Dasar (SD) di SD Negeri 2 Beringin Raya dan lulus pada tahun 2015. Selanjutnya, penulis menempuh pendidikan di Sekolah Menengah Pertama (SMP) Negeri 14 Bandar Lampung dan lulus pada tahun 2018, lalu melanjutkan ke Sekolah Menengah Atas (SMA) Negeri 7 Bandar Lampung dan menyelesaiannya pada tahun 2021.

Pada tahun 2021 penulis terdaftar sebagai mahasiswa Jurusan Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung melalui jalur SNMPTN. Selama menempuh pendidikan di perguruan tinggi, penulis melakukan beberapa kegiatan antara lain:

1. Menjadi penerima beasiswa Karya Salemba Empat tahun 2022 - 2025
2. Menjadi Asisten Dosen Jurusan Ilmu Komputer pada mata kuliah Dasar-Dasar Pemrograman dan Struktur Data dan Algoritma tahun ajaran 2022/2023.
3. Menjadi anggota Bidang Pendristek Paguyuban KSE UNILA pada periode 2022/2023.
4. Menjadi anggota Bidang Keilmuan Himpunan Mahasiswa Jurusan Ilmu Komputer pada periode 2023.
5. Menjadi ketua Bidang Kominfo Paguyuban KSE UNILA pada periode 2023/2024.

6. Melaksanakan kerja praktik periode 2023/2024 di PT PLN (Persero) UP2D Lampung.
7. Mengikuti program MSIB Batch 6 bersama Startup Campus di bidang dan memperoleh sertifikat di bidang *Data Science* dan *Artificial Intelligence* pada tahun 2024.
8. Menjadi delegasi dari Universitas Lampung untuk melaksanakan KKN Bilateral bersama Universitas Bengkulu dan Institut Teknologi Sumatera di Desa Sumber Agung, Kecamatan Arma Jaya, Kabupaten Bengkulu Utara, Provinsi Bengkulu pada bulan Juli hingga Agustus 2024 , sebagai bentuk pengabdian kepada masyarakat.

MOTTO

“A year ago, you didn’t know today. You didn’t know how you’d make it here. But you made it here. By grace, you made it here.”

- Morgan Harper Nichols

“Don’t cry because it’s over, smile because it happened.”

- Dr. Seuss

PERSEMBAHAN

Alhamdulillahirobbilalamin

Puji Syukur kehadirat Allah Subhanahu Wa Ta'ala atas segala Rahmat dan karunia-Nya sehingga skripsi ini dapat diselesaikan dengan sebaik-baiknya.

Shalawat serta salam selalu tercurahkan kepada junjungan Nabi Agung Muhammad Shallallahi 'Alaihi Wassalam.

Kupersembahkan karya ini kepada:

Kedua orang tuaku tercinta yang senantiasa memberikan doa, dukungan, dan kasih sayang tanpa henti. Juga kepada seluruh rekan yang telah membersamai dan membantu dalam proses penyusunan skripsi ini. Tak lupa, untuk diriku sendiri, sebagai bentuk apresiasi atas perjuangan dan ketekunan dalam menyelesaikan studi di Program Studi S1 Ilmu Komputer, Universitas Lampung

SANWACANA

Puji syukur kehadirat Allah SWT atas segala rahmat, nikmat, dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul **“Perbandingan Kinerja Arsitektur *EfficientNetV2B0* dan *Xception* untuk Klasifikasi Tumbuhan Obat Berdasarkan Citra Daun”**. Banyak pihak yang telah membantu penulis dalam menyelesaikan skripsi ini. Dengan segala kerendahan hati dan rasa hormat, penulis mengucapkan terimakasih kepada:

1. Allah Subhanahu Wa Ta’ala atas limpahan rahmat dan karunia-Nya yang telah diberikan sehingga penulis dapat menyelesaikan skripsi ini.
2. Ibu, Ayah, Mamas, dan Adek yang selalu menyayangi, menyemangati, dan mendoakan dalam setiap proses yang penulis lalui. Terima kasih karena telah menjadi tempat pulang yang paling aman, serta selalu memberikan dukungan atas setiap keputusan terbaik yang penulis ambil.
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 FMIPA Universitas Lampung.
5. Bapak Tristiyanto, S.Kom., M.I.S., Ph.D. selaku Ketua Program Studi S1 -Ilmu Komputer sekaligus Dosen Penguji Utama yang telah memberikan kritik dan saran untuk kemajuan dalam penyelesaian skripsi ini.
6. Ibu Yunda Heningtyas, M.Kom. selaku Sekretaris Jurusan Ilmu Komputer sekaligus Dosen Pembimbing Utama atas seluruh kebaikan dan keikhlasannya dalam membimbing penulis, serta dukungan, saran dan kritik yang diberikan dalam proses penyusunan dan penyelesaian skripsi ini.

7. Bapak Wartariyus, S.Kom., M.T.I. selaku Dosen Pembimbing Kedua yang telah memberikan arahan dan bimbingan serta motivasi yang sangat bermanfaat kepada penulis disetiap kesempatannya.
8. Bapak M. Iqbal Parabi, S.Si., M.T. selaku Pembimbing Akademik yang telah senantiasa membimbing dan memberikan saran masukan selama berkuliah di Jurusan Ilmu Komputer FMIPA Universitas Lampung.
9. Bapak/Ibu Dosen dan seluruh Staf Jurusan Ilmu Komputer FMIPA Universitas Lampung yang telah memberikan ilmu dan membantu dalam berbagai urusan akademik maupun administratif.
10. Yayasan Karya Salemba Empat (KSE) yang telah memberikan beasiswa, motivasi, relasi dan program yang luar biasa kepada penulis.
11. Siti Ayuni teman seperjuangan dalam menyusun skripsi atas segala perjuangan, kebersamaan, kesabaran serta segala hal baik yang telah diberikan. Terima kasih telah menjadi sobat juang sejak masa Kerja Praktik, MBKM, hingga penyusunan skripsi ini.
12. Teman-teman tersayang: Ayuni, Shafa, Nabillah, Abiyyi, Cindy, Jihan, Ikhsan, dan Roy yang selalu menjadi tempat berbagi canda, cerita dan pikiran selama masa perkuliahan. Terima kasih atas segala dukungan dan bantuan yang tak terhitung jumlahnya kehadiran kalian menjadi salah satu alasan penulis dapat menjalani dan menyelesaikan perkuliahan ini dengan baik.
13. Saka Arif Aulia yang sedari awal dimulainya perjalanan skripsi ini senantiasa memberikan dukungan dan bantuan kepada penulis. Terima kasih telah menjadi tempat berbagi keluh kesah, kebahagiaan dan segala cerita sepanjang proses penulisan skripsi ini.
14. Paguyuban KSE Unila beserta seluruh penghuninya atas segala pengalaman berharga, kebersamaan dan keseruan yang telah mewarnai perjalanan penulis selama menjadi bagian dari keluarga besar ini terima kasih atas dukungan dan semangat yang tak pernah putus.
15. Keluarga Ilmu Komputer Angkatan 2021 yang telah menjadi bagian dari perjalanan ini terima kasih atas kebersamaan dan dukungan yang senantiasa diberikan masa perkuliahan di Jurusan Ilmu Komputer Universitas Lampung.

16. Kepada seluruh pihak yang tidak dapat disebutkan satu per satu namun telah memberikan dukungan dan kontribusi yang berarti dalam proses penyusunan skripsi ini penulis mengucapkan terima kasih.

Penulis menyadari bahwa skripsi ini masih memiliki banyak kekurangan dan belum sepenuhnya sempurna. Meski demikian besar harapan penulis agar karya ini dapat memberikan manfaat bagi civitas akademika Universitas Lampung terkhusus mahasiswa Ilmu Komputer.

Bandar Lampung, 28 Juli 2025



Vidya Sinta Billkis
NPM. 2117051029

DAFTAR ISI

	Halaman
DAFTAR GAMBAR	ix
DAFTAR TABEL	xii
DAFTAR KODE PROGRAM	xiii
I. PENDAHULUAN	1
1.1. Latar Belakang dan Masalah	1
1.2. Rumusan Masalah.....	4
1.3. Batasan Masalah	4
1.4. Tujuan Penelitian	5
1.5. Manfaat Penelitian	5
II. TINJAUAN PUSTAKA	6
2.1. Penelitian Terdahulu	6
2.2. Tumbuhan Obat.....	9
2.2.1. Sirih Hijau (<i>Piper betle Linn</i>)	10
2.2.2. Binahong (<i>Anredera cordifolia</i>)	11
2.2.3. Kejibeling (<i>Serycocalyx crispus L</i>)	11
2.2.4. Salam (<i>Eugenia polyantha Wight</i>).....	12
2.2.5. Pulai (<i>Alstonia scholaris</i>).....	13
2.2.6. Kelor (<i>Moringa oleifera Lam</i>)	14
2.2.7. Bidara (<i>Ziziphus mauritiana</i>).....	15
2.2.8. Cincau Hijau (<i>Cyclea barbata L. Miers</i>)	16
2.2.9. Sambung Nyawa (<i>Gynura procumbens</i>).....	17
2.2.10. Ketapang (<i>Terminalia catappa</i>)	18
2.3. <i>Deep Learning</i>	19

2.4. <i>Transfer Learning</i>	20
2.5. <i>Convolutional Neural Network (CNN)</i>	21
2.5.1. <i>Convolutional Layer (Conv. Layer)</i>	22
2.5.2. Fungsi Aktivasi <i>SiLU</i>	23
2.5.3. Fungsi Aktivasi <i>ReLU</i>	23
2.5.4. <i>Pooling Layer</i>	24
2.5.5. <i>Flatten Layer</i>	24
2.5.6. <i>Fully Connected Layer (FC. Layer)</i>	25
2.5.7. Fungsi Aktivasi <i>Softmax</i>	26
2.6. <i>EfficientNetV2B0</i>	26
2.7. <i>Xception</i>	28
2.8. <i>Dataset</i>	29
2.9. <i>Preprocessing</i>	30
2.9.1. <i>Resize</i>	30
2.9.2. Normalisasi	31
2.10. <i>Training Model</i>	31
2.10.1. <i>Optimizer</i>	32
2.10.2. <i>Learning Rate</i>	32
2.10.3. <i>Epoch</i>	32
2.10.4. <i>Batch Size</i>	33
2.10.5. <i>Early Stopping</i>	33
2.11. <i>Confusion Matrix</i>	34
2.11.1. Akurasi	35
2.11.2. Presisi	35
2.11.3. <i>Recall</i>	35
2.11.4. <i>F1-Score</i>	36
2.12. <i>Streamlit</i>	36
2.13. <i>Black Box</i>	37
III. METODOLOGI PENELITIAN	38
3.1. Tempat dan Waktu Penelitian	38
3.1.1. Tempat Penelitian	38
3.1.2. Waktu Penelitian	38

3.2. Perangkat Penelitian	39
3.2.1. Perangkat Keras.....	39
3.2.2. Perangkat Lunak	39
3.3. Tahap Penelitian.....	40
3.3.1. Studi Literatur.....	40
3.3.2. Pengumpulan Dataset.....	42
3.3.3. <i>Preprocessing</i>	43
3.3.4. <i>Modeling EfficientNetV2B0</i>	45
3.3.5. <i>Modelling Xception</i>	46
3.3.6. Evaluasi.....	48
3.3.7. Pengembangan Sistem	49
IV. HASIL DAN PEMBAHASAN	52
4.1. Pengumpulan <i>Dataset</i>	52
4.2. <i>Preprocessing</i>	55
4.2.1. <i>Resizing Data</i>	55
4.2.2. Normalisasi Data	56
4.2.3. <i>Splitting Data</i>	58
4.3. <i>Modeling EfficientNetV2B0</i>	60
4.3.1. Inisialisasi Model <i>EfficientNetV2B0</i>	60
4.3.2. <i>Training Model EfficientNetV2B0</i>	61
4.3.3. <i>Testing Model EfficientNetV2B0</i>	64
4.4. <i>Modeling Xception</i>	71
4.4.1. Inisialisasi Model <i>Xception</i>	71
4.4.2. <i>Training Model Xception</i>	72
4.4.3. <i>Testing Model Xception</i>	75
4.5. Evaluasi	82
4.6. Pengembangan Sistem.....	83
4.6.1. Desain <i>Unified Modeling Language</i> (UML)	83
4.6.2. Implementasi Sistem	84
4.6.3. Pengujian Sistem	87
4.7. Pembahasan.....	88

V. SIMPULAN DAN SARAN.....	92
5.1. Simpulan.....	92
5.2. Saran	92
DAFTAR PUSTAKA.....	94
LAMPIRAN	101

DAFTAR GAMBAR

Gambar	Halaman
1. Daun Sirih Hijau.	10
2. Daun Binahong.	11
3. Daun Kejibeling.	12
4. Daun Salam.	13
5. Daun Pulai.	14
6. Daun Kelor.	15
7. Daun Bidara.	16
8. Daun Cincau Hijau.	17
9. Daun Sambung Nyawa.	18
10. Daun Ketapang.	19
11. Transfer Learning.	20
12. Arsitektur CNN.	21
13. Proses konvolusi.	22
14. Grafik fungsi aktivasi <i>ReLU</i>	23
15. Ilustrasi proses pada <i>pooling layer</i>	24
16. Ilustrasi proses pada <i>flatten layer</i>	25
17. Ilustrasi proses pada <i>fully connected layer</i>	25
18. Grafik fungsi aktivasi <i>softmax</i>	26
19. Arsitektur <i>EfficientNetV2</i>	27
20. Struktur dari <i>MBConv</i> dan <i>Fused-MBConv</i>	28
21. Arsitektur <i>Xception</i>	29
22. <i>Confussion matrix</i> multi kelas.	34
23. Tahap penelitian.	41
24. Arsitektur model <i>EfficientNetV2B0</i>	46
25. Arsitektur model <i>Xception</i>	47

26. <i>Use Case Diagram</i>	49
27. <i>Activity diagram</i> melihat panduan penggunaan.	50
28. <i>Activity diagram</i> mengunggah dan melihat klasifikasi.....	50
29. Data tumbuhan obat dari penelitian Lestari (2023).	53
30. Ilustrasi proses pengambilan gambar.	53
31. Data tumbuhan obat dari hasil pengambilan langsung.	54
32. Transformasi <i>resizing</i> untuk setiap ukuran.	56
33. Ilustrasi hasil normalisasi data.	57
34. Hasil proses <i>training</i> dan validasi <i>EfficientNetV2B0</i> tanpa normalisasi data. 58	58
35. Hasil proses <i>training</i> dan validasi <i>Xception</i> tanpa normalisasi data.....	58
36. Grafik akurasi dan <i>loss training</i> dan validasi skema 80:10:10.	64
37. Grafik akurasi dan <i>loss training</i> dan validasi skema 70:20:10.	64
38. <i>Confussion matrix</i> <i>EfficientNetV2B0</i> skema 80:10:10.	65
39. Kesalahan klasifikasi model <i>EfficientNetV2B0</i> pada skema 80:10:10.	66
40. Analisis kemiripan daun sambung nyawa dan daun kejibeling.	67
41. <i>Confussion matrix</i> <i>EfficientNetV2B0</i> skema 70:20:10.	68
42. Kesalahan klasifikasi model <i>EfficientNetV2B0</i> pada skema 70:20:10.	69
43. Analisis kemiripan daun cincau dan daun sirih.	70
44. Analisis kemiripan daun ketapang dan daun salam.	70
45. Grafik akurasi dan <i>loss training</i> dan validasi skema 80:10:10.	74
46. Grafik akurasi dan <i>loss training</i> dan validasi skema 70:20:10.	74
47. <i>Confusion matrix</i> <i>Xception</i> skema 80:10:10.	75
48. Kesalahan klasifikasi model <i>Xception</i> pada skema 80:10:10.....	77
49. Analisis kemiripan daun ketapang dan daun sambung nyawa.	78
50. Analisis kemiripan daun binahong dan daun sirih.	78
51. Analisis kemiripan daun cincau dan daun ketapang.	78
52. Analisis kemiripan daun ketapang dan daun salam.	78
53. <i>Confusion matrix</i> <i>Xception</i> skema 70:20:10.	79
54. Kesalahan klasifikasi model <i>Xception</i> pada skema 70:20:10.....	81
55. Analisis kemiripan daun ketapang dan sambungnyawa.	81
56. Analisis kemiripan daun ketapang dan daun salam.	82
57. Analisis kemiripan daun cincau dan daun ketapang.	82

58. Tampilan halaman panduan.....	85
59. Tampilan halaman klasifikasi.....	86
60. Tampilan halaman klasifikasi saat berhasil mengklasifikasikan.....	86
61. Tingkat <i>confidence</i> data uji pada model <i>EfficientNetV2B0</i>	89
62. Tingkat <i>confidence</i> data uji pada model <i>Xception</i>	89

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terdahulu.	6
2. Timeline Penelitian.	38
3. Lokasi Pengambilan Data.	43
4. <i>Hyperparamater training model EfficientNetV2B0</i>	45
5. <i>Hyperparameter training model Xception</i>	48
6. Skenario pengujian <i>black box testing</i>	51
7. Data dari penelitian Lestari (2023).	52
8. Data dari pengambilan langsung.	54
9. Ukuran gambar sebelum dan sesudah <i>resize</i>	55
10. Perhitungan normalisasi data.	57
11. <i>Hyperparameter training model EfficientNetV2B0</i>	62
12. Hasil perhitungan <i>confussion matrix</i> model <i>EfficientNetV2B0</i> skema 80:10:10.....	65
13. Hasil perhitungan <i>confussion matrix</i> model <i>EfficientNetV2B0</i> skema 70:20:10.....	68
14. <i>Hyperparamater training model Xception</i>	73
15. Hasil perhitungan <i>confussion matrix</i> model <i>Xception</i> skema 80:10:10.	76
16. Hasil perhitungan <i>confussion matrix</i> model <i>Xception</i> skema 70:20:10.	79

DAFTAR KODE PROGRAM

Kode Program	Halaman
1. <i>Resize</i> gambar.....	55
2. Normalisasi data.....	56
3. <i>Splitting</i> data skema 80:10:10.....	59
4. <i>Splitting</i> data skema 70:20:10.....	59
5. Inisialisasi model <i>EfficientNetV2B0</i>	61
6. Training model <i>EfficientNetV2B0</i>	63
7. Inisialisasi model <i>Xception</i>	72
8. Training model <i>Xception</i>	74
9. Fungsi <i>preprocessing</i> gambar di <i>website</i>	84

I. PENDAHULUAN

1.1. Latar Belakang dan Masalah

Indonesia, sebagai negara beriklim tropis, memiliki kekayaan biodiversitas yang sangat tinggi, termasuk dalam hal tumbuhan obat (Utomo dkk., 2020). Dari sekitar 40 ribu jenis tumbuhan obat yang dikenal di seluruh dunia, sekitar 30 ribu diantaranya terdapat di Indonesia (Salim & Munadi, 2017). Tumbuhan-tumbuhan ini khususnya bagian daun, telah lama dimanfaatkan dalam pengobatan tradisional karena kandungan vitamin, mineral, antioksidan, dan zat bermanfaat lainnya (Herdiansah dkk., 2022). Meskipun demikian, pengidentifikasiannya berbagai jenis tumbuhan obat ini sering kali menjadi tantangan, terutama karena keragaman bentuk dan karakteristik yang dimiliki setiap tumbuhan.

Identifikasi tumbuhan obat sangat penting dalam berbagai aspek, khususnya dalam dunia medis, karena dapat memastikan penggunaan yang tepat dan efektif dari tumbuhan tersebut untuk pengobatan (Arnandito & Sasongko, 2024). Namun, kekayaan varietas tumbuhan obat menimbulkan tantangan dalam identifikasi langsung (Mujahid dkk., 2024). Identifikasi daun tumbuhan obat umumnya dilakukan berdasarkan bentuk dan warna (Mardiana dkk., 2023). Akan tetapi, keragaman morfologi daun di Indonesia membuat proses ini menjadi lebih kompleks, karena setiap tumbuhan memiliki bentuk yang berbeda-beda. Dua di antara bentuk daun yang paling umum dijumpai adalah bentuk jantung (*cordate*) dan bulat telur (*ovate*) (Nurdiana, 2020), yang sering kali sulit dibedakan secara kasat mata. Keragaman tersebut menjadikan proses identifikasi manual seringkali memerlukan waktu yang lama, pengetahuan botani yang memadai, serta

keahlian khusus. Oleh karena itu, diperlukan media yang efektif dan akurat untuk mengidentifikasi berbagai jenis tumbuhan obat. Salah satu solusinya adalah dengan menggunakan teknologi untuk menyajikan informasi tentang klasifikasi tumbuhan obat (Jeon & Rhee, 2017).

Teknologi yang dapat digunakan untuk mengklasifikasikan tumbuhan obat berdasarkan citra daun adalah algoritma *artificial intelligence* melalui metode *machine learning*, yaitu *deep learning*. Menurut Samuel (1995), *machine learning* adalah bidang ilmu komputer yang memungkinkan komputer untuk belajar tanpa memerlukan pemrograman eksplisit (Samuel, 1959). *Deep learning* merupakan evolusi dari *machine learning* yang sering digunakan dalam pemrosesan gambar atau citra digital (Peryanto dkk., 2019). Contoh algoritma *deep learning* yang sering digunakan adalah *Convolutional Neural Network* (CNN), dengan model arsitektur seperti *efficientNet*.

EfficientNet merupakan arsitektur CNN yang dikembangkan oleh Mingxing Tan dan Quoc V. Le pada tahun 2019. Arsitektur ini memperbesar lebar, kedalaman, dan resolusi citra secara bersamaan dengan menggunakan koefisien gabungan (Tan & Le, 2019) dan terdiri dari tujuh model berbeda, mulai dari B0 hingga B7, dengan variasi jumlah blok *MBConv* di setiap modelnya (Irsyad dkk., 2023). Dalam penelitian berjudul “*Herbal Leaf Classification Using Deep Learning Model EfficientNetV2B0*” oleh Putra dan rekan-rekannya pada tahun 2024, model *EfficientNetV2B0* berhasil digunakan untuk mengklasifikasikan daun herbal dengan dataset berjumlah 3500 citra daun dari 10 kelas, mencapai akurasi sebesar 99,14% pada data uji (Putra dkk., 2024). Temuan ini sejalan dengan penelitian Nurfauzi dan rekan-rekannya pada tahun 2023 yang juga menunjukkan bahwa *EfficientNetV2B0* dipilih karena efisiensinya yang lebih baik dan presisinya yang lebih tinggi dibandingkan arsitektur lain dalam tugas klasifikasi (Nurfauzi dkk., 2023).

Selain arsitektur *EfficientNet*, arsitektur *Xception* juga sering digunakan dalam mengklasifikasikan citra. *Xception*, yang merupakan singkatan dari “*Extreme Inception*,” adalah arsitektur CNN yang diperkenalkan oleh François Chollet pada tahun 2017. Arsitektur ini mengandalkan *Depthwise*

Separable Convolutions untuk meningkatkan efisiensi komputasi tanpa mengorbankan akurasi. *Xception* dikembangkan dari arsitektur *Inception* dan terdiri dari 36 lapisan konvolusi yang berfungsi untuk ekstraksi fitur utama (Chollet, 2016). Dalam penelitian yang dilakukan oleh Bhelkar dan Sharma pada tahun 2022 dengan judul “*Identification and Classification of Medicinal Plants Using Leaf with Deep Convolutional Neural Networks*,” model *Xception* digunakan untuk mengidentifikasi citra daun tanaman obat. Penelitian ini menggunakan 4682 citra dari 45 kelas tanaman obat dan berhasil mencapai akurasi sebesar 97,65% (Bhelkar & Sharma, 2022). Temuan ini didukung oleh penelitian Carnagie dan rekan-rekannya pada tahun 2022, dimana model *Xception* dipilih karena dapat memberikan hasil akurasi klasifikasi yang jauh lebih baik dibandingkan dengan menyusun jaringan saraf dan semua nodenya secara manual. Pada penelitian tersebut, model *Xception* berhasil mencapai akurasi sebesar 93,3% pada data latih (Carnagie dkk., 2022).

Berdasarkan uraian di atas, penelitian ini akan membandingkan kinerja arsitektur *EfficientNetV2B0* dan *Xception* untuk mengklasifikasikan tumbuhan obat berdasarkan citra daun. Penelitian ini merupakan penelitian lanjutan dari skripsi Hani Cita Lestari yang berjudul "Klasifikasi Citra Daun Tumbuhan Obat Menggunakan Deteksi Tepi *Canny* dan Metode *K-Nearest Neighbor* (KNN)". Dalam penelitian sebelumnya, Hani Cita Lestari telah berhasil menerapkan metode deteksi tepi *Canny* dan KNN untuk mengklasifikasikan citra daun tumbuhan obat dan mendapatkan skor akurasi sebesar 81,33% (Lestari, 2023). Penelitian ini bertujuan untuk mengembangkan dan memperluas hasil tersebut dengan menggunakan pendekatan yang lebih inovatif, yaitu perbandingan kinerja antara arsitektur *EfficientNetV2B0* dan *Xception*, serta penambahan *dataset* tumbuhan obat. Dalam *dataset* yang digunakan, citra daun yang diambil mencakup dua bentuk morfologi yaitu, bentuk jantung (*cordate*) dan bulat telur (*ovate*). Kedua morfologi daun tersebut dipilih untuk menggambarkan keragaman bentuk daun yang ada di Indonesia, yang menjadi tatangan dalam proses klasifikasi tumbuhan obat. Hasil dari penelitian ini akan diimplementasikan

dalam bentuk aplikasi berbasis *web* yang dapat digunakan untuk mengidentifikasi jenis-jenis tumbuhan obat. Diharapkan, penelitian ini dapat memberikan wawasan mengenai keunggulan masing-masing arsitektur dalam klasifikasi citra daun tumbuhan obat dan memberikan kontribusi yang signifikan dalam pengembangan teknologi identifikasi tumbuhan obat di Indonesia.

1.2. Rumusan Masalah

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

- a. Pengembangan model klasifikasi tumbuhan obat berdasarkan citra daun menggunakan arsitektur *EfficientNetV2B0* dan *Xception*.
- b. Perbandingan tingkat akurasi klasifikasi tumbuhan obat berdasarkan citra daun antara arsitektur *EfficientNetV2B0* dan *Xception*.
- c. Pengembangan aplikasi berbasis *web* yang dapat mengunggah citra daun tumbuhan dan memberikan respon berupa hasil klasifikasi jenis tumbuhan obat dari daun tersebut.

1.3. Batasan Masalah

Agar penelitian tidak menyimpang dari tujuan yang diharapkan, maka ditetapkan batasan masalah dalam penelitian ini yaitu:

- a. *Dataset* dalam penelitian ini adalah citra daun tumbuhan obat dari sepuluh jenis tumbuhan, yaitu daun sirih hijau (*Piper betle Linn*), daun binahong (*Anredera cordifolia*), daun kejibeling (*Servycocalyx crispus L*), daun salam (*Eugenia polyantha Wight*), daun pulai (*Alstonia scholaris*), daun kelor (*Moringa oleifera Lam*), daun bidara (*Ziziphus mauritiana*), daun cincau hijau (*Cyclea barbata L. Miers*), daun sambung nyawa (*Gynura procumbens*), dan daun ketapang (*Terminalia catappa*).

-
- b. Gambar daun yang digunakan dalam penelitian ini terbatas pada daun tunggal dengan latar belakang berwarna putih.

1.4. Tujuan Penelitian

Penelitian ini memiliki beberapa tujuan, yaitu:

- a. Mengembangkan model dengan arsitektur *EfficientNetV2B0* dan *Xception* yang dapat mengklasifikasikan tumbuhan obat berdasarkan citra daun.
- b. Mengetahui perbedaan tingkat akurasi model antara arsitektur *EfficientNetV2B0* dan *Xception* dalam klasifikasi tumbuhan obat berdasarkan citra daun.
- c. Mengembangkan aplikasi berbasis *web* yang dapat mengunggah citra daun tumbuhan dan memberikan respon berupa hasil klasifikasi jenis tumbuhan obat dari daun tersebut.

1.5. Manfaat Penelitian

Manfaat dari penelitian ini adalah sebagai berikut:

- a. Memberikan wawasan mengenai pengembangan dan performa akurasi arsitektur *EfficientNetV2B0* dan *Xception* dalam klasifikasi tumbuhan obat berdasarkan citra daun.
- b. Menyediakan sistem klasifikasi berbasis *web* untuk mengidentifikasi jenis tumbuhan obat dari citra daun, yang memudahkan dan mempercepat proses pengenalan tumbuhan obat.

II. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Penelitian terdahulu mengenai klasifikasi citra daun tumbuhan obat telah dilakukan dengan berbagai pendekatan dan metode. Beberapa penelitian yang relevan dapat dilihat pada Tabel 1.

Tabel 1. Penelitian Terdahulu.

Penulis	Judul	Metode	Hasil
Lestari, 2023	Klasifikasi Citra Daun Tumbuhan Obat Menggunakan Deteksi Tepi Canny dan Metode K-Nearest Neighbor (KNN)	Deteksi tepi Canny dan KNN	Penelitian tersebut berhasil menerapkan metode deteksi tepi <i>Canny</i> dan KNN untuk mengklasifikasikan citra daun tumbuhan obat dan mendapatkan skor akurasi sebesar 81,33%.
Putra dkk., 2024	<i>Herbal Leaf Classification Using Deep Learning Model EfficientNetV2B0</i>	<i>Convolutional Neural Network</i> (CNN)	Penelitian tersebut berhasil membuat model dengan arsitektur <i>EfficientNetV2B0</i> untuk mengklasifikasikan daun herbal. Model yang dibuat mendapatkan skor akurasi 99,14% dengan nilai <i>loss</i> 1,95%.
Bhelkar & Sharma, 2022	<i>Identification and Classification of Medicinal Plants using Leaf with Deep Convolutional Neural Network</i>	<i>Convolutional Neural Network</i> (CNN)	Penelitian tersebut berhasil mengembangkan model arsitektur <i>Xception</i> untuk mengidentifikasi dan mengklasifikasikan tumbuhan obat. Model tersebut berhasil mendapatkan skor akurasi sebesar 97,65%.

Tabel 1. Lanjutan.

Penulis	Judul	Metode	Hasil
Novalina & Rizkinia, 2023	<i>Implementation of Xception and EfficientNetB3 for COVID-19 Detection on Chest X-Ray Image via Transfer Learning</i>	<i>Convolutional Neural Network</i> (CNN)	Penelitian tersebut berhasil menggunakan teknik <i>transfer learning</i> pada arsitektur <i>EfficientNetB3</i> dan <i>Xception</i> dalam mendekripsi COVID-19 berdasarkan citra rontgen dada. Hasilnya model <i>EfficientNetB3</i> lebih baik dengan akurasi 95.28%, sedangkan <i>Xception</i> berhasil dengan akurasi 94.44%.

Penelitian yang dilakukan oleh Lestari (2023) menggunakan metode deteksi tepi *canny* dan KNN untuk mengklasifikasikan citra daun tumbuhan obat. Dataset yang digunakan terdiri atas 900 citra daun, yang terbagi ke dalam tiga kelas: daun sirih (*piper betle*), daun binahong (*anredera cordifolia*), dan daun kejibeling (*strobilanthes crispus*), masing masing berjumlah 300 citra. Data ini dibagi menjadi 80% data latih dan 20% data uji untuk setiap kelas. Pada tahap deteksi tepi menggunakan metode *Canny*, gambar diubah menjadi format *grayscale*, dan kemudian dilakukan reduksi *noise* untuk meningkatkan kualitas gambar. Setelah itu, dilakukan ekstraksi fitur, dengan fitur-fitur yang digunakan meliputi *area*, *perimeter*, *eccentricity*, *solidity*, *aspect ratio*, *num edges*, *total edge length*, dan *average edge distance*. Nilai fitur yang diperoleh kemudian digunakan sebagai kriteria dalam perhitungan KNN. Berdasarkan hasil pengujian, data uji untuk daun kejibeling mencapai akurasi tertinggi sebesar 100%. Sementara itu, daun binahong memiliki tingkat akurasi sebesar 82,49%, dan daun sirih menunjukkan tingkat akurasi terendah, yaitu 61,13%. Kesalahan identifikasi tersebut dapat terjadi akibat tepi objek yang kurang sempurna, sehingga dapat memengaruhi hasil klasifikasi. Secara keseluruhan, rata-rata akurasi tertinggi yang diperoleh adalah 81,33% pada nilai parameter $k = 4$, dengan validasi menggunakan metode *5-Fold Cross Validation*.

Sementara itu, pendekatan berbasis *deep learning* telah dimanfaatkan oleh Putra, dkk. (2024), yang mengimplementasikan arsitektur *EfficientNetV2B0* untuk klasifikasi daun herbal. *Dataset* yang digunakan diambil dari *website mendeley* dengan judul “*Indonesian Herb Leaf Dataset 3500*,” yang terdiri dari 10 kelas daun herbal, yaitu belimbing wuluh, jambu biji, jeruk nipis, kemangi, lidah buaya, nangka, pandan, pepaya, seledri, dan sirih yang masing-masing berjumlah 350 citra sehingga total citra yang digunakan 3500 citra. *Dataset* tersebut kemudian dibagi menjadi data latih, data validasi, dan data uji dengan rasio 8:1:1 untuk setiap jenis daun herbal. *Preprocessing* yang dilakukan dalam penelitian ini meliputi *resize* gambar menjadi ukuran 224 x 224 piksel. Penelitian ini menggunakan *transfer learning* dengan *kernel* berukuran 3 x 3, serta menambahkan beberapa *layer*, diantaranya *MaxPooling2D*, *Flatten*, dan *Batch Normalization*. Setelah dilakukan proses pelatihan dan validasi sebanyak 30 epoch, dihasilkan sebuah model yang memiliki nilai akurasi pengujian sebesar 99,14% dan nilai *loss* 1,95%. Selain itu, arsitektur *Xception* juga telah diimplementasikan dalam penelitian oleh Bhelkar & Sharma (2022), yang memanfaatkan 4682 citra daun dari 45 jenis tumbuhan obat untuk proses identifikasi dan klasifikasi. *Dataset* tersebut dibagi menjadi data latih dan data validasi dengan 10 rasio 7:3. Penelitian ini menggunakan *transfer learning* dan memodifikasi *output layer*-nya menjadi 45 sesuai dengan kelas yang akan diklasifikasikan. Melalui proses pelatihan dan validasi sebanyak 50 epoch, model dihasilkan menunjukkan nilai akurasi pelatihan sebesar 98,40% dan nilai akurasi validasi sebesar 97,65%

Penelitian yang secara langsung membandingkan arsitektur *EfficientNet* dan *Xception* pernah dilakukan oleh Novalina & Rizkina (2023), yang membandingkan performa *EfficientNetB3* dan *Xception* dalam deteksi COVID-19 berdasarkan citra rontgen dada. *Dataset* yang digunakan dalam penelitian ini berjumlah 4000 data citra rontgen dada yang terbagi ke dalam 4 kelas, dengan masing-masing kelas berisi 1000 citra. *Dataset* ini diperoleh dari data publik “*Curated Dataset for COVID-19 Posterior-Anterior Chest Radiography Images (X-Rays)*” Versi 3[8]. Penelitian ini membagi data ke dalam beberapa skema pembagian, yaitu rasio 70:30, 80:20, 90:10, serta

menggunakan metode *5-fold cross-validation*. *Preprocessing* yang dilakukan dalam penelitian ini mencakup mengubah ukuran gambar menjadi 224x224 piksel dan menerapkan augmentasi data, yang meliputi *rescale*, *rotation_range*, *height_shift_range*, *width_shift_range*, *shear_range*, *zoom_range*, *horizontal_flip*, *vertical_flip*, dan *fill_mode*. Pada proses *training* model, digunakan 60 *epoch*, *batch size* 16, serta *optimizer Adam* dengan *learning rate* 0.0001. Penelitian ini menggunakan *pretrained model Xception* dengan *weight ImageNet* dan *EfficientNetB3* dengan *weight noisy-student*. Penelitian ini juga menambahkan beberapa *layer*, yaitu *Global Average Pooling*, *Dense Layer* dengan 256 *node* dan *aktivasi ReLU*, *Dropout Layer*, *Batch Normalization*, dan *Output Layer* dengan fungsi aktivasi *Softmax*. Setelah proses *training* dilakukan, diketahui bahwa skema pembagian data dengan rasio 90:10 memberikan hasil terbaik, dengan akurasi *Xception* 94,44% dan *EfficientNetB3* 95,28%.

2.2. Tumbuhan Obat

Tumbuhan obat adalah tumbuhan yang memiliki khasiat sebagai obat dan digunakan untuk mengurangi, mengatasi, atau menyembuhkan penyakit pada seseorang (Haba dkk., 2022). Pengobatan dengan memanfaatkan tumbuhan obat ini telah berlangsung sejak ribuan tahun lalu dan banyak diterapkan di berbagai belahan dunia, termasuk dalam tradisi Aryurveda, pengobatan tradisional Tiongkok, dan jamu di Indonesia. Tumbuhan-tumbuhan ini dapat dikonsumsi sebagai obat dengan berbagai cara, seperti dijadikan teh, diolah menjadi ekstrak, dibuat menjadi jamu (Rai dkk., 2023), ditempelkan pada kulit, atau dihirup (Sarno, 2019). Beberapa bagian dari tumbuhan yang dapat dimanfaatkan sebagai obat mencakup akar, rimpang, kulit batang, daun, buah, dan bunga (Rai dkk., 2023). Dalam konteks klasifikasi tumbuhan obat, daun sering menjadi objek utama karena mudah diamati dan memiliki variasi bentuk yang khas. Morfologi daun di Indonesia sangat beragam, dua di

antaranya adalah bentuk jantung (*cordate*) dan bulat telur (*ovate*) (Nurdiana, 2020), yang juga digunakan dalam *dataset* penelitian ini.

2.2.1. Sirih Hijau (*Piper betle Linn*)

Sirih hijau (*Piper betle Linn*) merupakan salah satu tumbuhan yang sering dimanfaatkan oleh masyarakat sebagai obat tradisional. Berdasarkan Keputusan Menteri Kesehatan Republik Indonesia Nomor HK.01.07/MENKES/187/2017 tentang Formularium Ramuan Obat Tradisional Indonesia, daun sirih berkhasiat sebagai obat mimisan, sakit tenggorokan dan jerawat (Kementerian Kesehatan Republik Indonesia, 2017). Selain itu, sirih juga efektif untuk mengobati sariawan, mengurangi gatal-gatal (Qonitah & Ahwan, 2018), serta berpotensi sebagai antibakteri dan berbagai manfaat lainnya (Sadiyah dkk., 2022). Tumbuhan ini tumbuh merambat hingga mencapai 15 meter. Batangnya cokelat kehijauan, bulat, berkerut, beruas sebagai tempat keluarnya akar. Daunnya berbentuk jantung dengan ujung lancip, tumbuh berselang-seling, bertangkai, bertekstur agak kasar. Saat diremas, daun mengeluarkan aroma harum, dengan panjang 6-17,5 cm dan lebar 3,5-10 cm (Moeljanto & Mulyono, 2003). Bentuk tumbuhan sirih dapat dilihat pada Gambar 1.



Gambar 1. Daun Sirih Hijau (Yogasuria, 2011).

2.2.2. Binahong (*Anredera cordifolia*)

Binahong (*Anredera cordifolia*) adalah tumbuhan yang juga cukup populer dalam pengobatan tradisional di Indonesia. Tumbuhan ini memiliki banyak manfaat bagi kesehatan, antara lain untuk menyembuhkan luka luar akibat benda tajam, luka pasca-operasi, meningkatkan stamina tubuh, meredakan sakit maag, menyebuhkan memar, rematik, pegal linu, dan menghaluskan kulit (Manoi, 2019). Binahong merupakan jenis tumbuhan merambat dengan batang yang lunak, berbentuk silindris, dan saling membelit. Daunnya tunggal, bertangkai pendek, berwarna hijau, berbentuk jantung dengan panjang 5-10 cm. Akar tumbuhan ini berbentuk rimpang, dan berdaging lunak (Kidarsa, 2014). Gambar 2 memperlihatkan bentuk tumbuhan binahong.



Gambar 2. Daun Binahong (Lestari, 2023).

2.2.3. Kejibeling (*Serycocalyx crispus L*)

Kejibeling (*Serycocalyx crispus L*) adalah tumbuhan obat yang dikenal luas di Indonesia dan memiliki berbagai manfaat kesehatan. Masyarakat menggunakan daun ini untuk mengobati kencing batu

batu empedu, gigitan ular berbisa, urus-urus, batu ginjal, sembelit, wasir dan obat sakit kencing manis (Kementerian Kesehatan Republik Indonesia, 2015). Tumbuhan ini memiliki akar tunggang dan batang beruas-ruas, bulat, dan berwarna hijau. Daunnya tunggal, berhadapan, berbentuk bulat telur dan lonjong (Ambarwati dkk., 2024), berwarna hijau dengan permukaan bawah yang lebih pucat, dan bila diraba terasa kasar. Daun bertepi beringgit, ujung dan pangkalnya meruncing, panjang daun 9-18 cm dan lebar 3-8 cm (Silalahi, 2020). Bentuk tumbuhan kejibeling dapat dilihat pada Gambar 3.



Gambar 3. Daun Kejibeling (Silalahi, 2020).

2.2.4. Salam (*Eugenia polyantha Wight*)

Salam (*Eugenia polyantha Wight*) merupakan tumbuhan yang sering digunakan sebagai bahan penyedap dalam masakan, namun juga memiliki khasiat obat. Berdasarkan Keputusan Menteri Kesehatan Republik Indonesia Nomor HK.01.07/MENKES/187/2017 tentang Formularium Ramuan Obat Tradisional Indonesia, daun salam dapat dimanfaatkan sebagai obat untuk kencing manis (Kementerian Kesehatan Republik Indonesia, 2017). Selain itu, daun salam juga biasa digunakan untuk mengatasi kolesterol tinggi, tekanan darah tinggi, gastritis, dan diare. Tumbuhan ini berupa pohon yang tumbuh

tegak dan dapat mencapai tinggi hingga 25 meter, serta tumbuh di daerah dengan ketinggian 5-1000 meter di atas permukaan laut. Daunnya berbentuk bulat memanjang atau bulat telur, dengan bunga berwarna putih dan sedikit harum. Buahnya berwarna hijau saat muda dan berubah menjadi merah keunguan saat matang (Kementerian Kesehatan Republik Indonesia, 2015). Bentuk tumbuhan salam dapat dilihat pada Gambar 4.



Gambar 4. Daun Salam (Suprapto, 2020).

2.2.5. Pulai (*Alstonia scholaris*)

Pulai (*Alstonia scholaris*) merupakan pohon besar yang dikenal dengan berbagai manfaat dalam pengobatan tradisional. Bagian tumbuhan yang sering dimanfaatkan sebagai obat adalah kulit batangnya. Kulit batang pulai memiliki khasiat sebagai penghilang nyeri, penurun demam, serta untuk mengobati kencing manis. Selain itu, kulit batang pulai juga merupakan bahan utama yang sering digunakan dalam penyusunan ramuan jamu tradisional (Kementerian Kesehatan Republik Indonesia, 2015). Tumbuhan ini berupa pohon dengan tinggi 10-50 meter, dengan batang lurus yang memiliki diameter hingga 60 cm. Daunnya tersusun secara melingkar, terdiri dari 4 hingga 9 helai dengan pertulangan menyirip, berwarna hijau,

berbentuk telur memanjang dan lanset (Perpustakaan Kementerian Pekerjaan Umum, 2025). Kulit batang pulai rapuh, memiliki rasa sangat pahit, permukaan berbintil lentisel, tebal 6-8 mm, berwarna putih di bagian dalam, dan ketika dipotong kulit batang mengeluarkan getah berwarna putih (Mayor & Wattimena, 2022). Bentuk tumbuhan pulai dapat dilihat pada Gambar 5.



Gambar 5. Daun Pulai (Bame, 2020).

2.2.6. Kelor (*Moringa oleifera Lam*)

Kelor (*Moringa oleifera Lam*) adalah tumbuhan yang terkenal karena kandungan nutrisinya yang sangat tinggi dan manfaatnya dalam pengobatan tradisional. Bagian tumbuhan kelor yang sering digunakan sebagai obat meliputi biji, bunga, kayu, dan daun (Susanti & Nurman, 2022). Kelor dimanfaatkan oleh masyarakat untuk mengobati berbagai penyakit, seperti darah tinggi, kolesterol, asam urat, kanker, gangguan lambung, diabetes, jerawat, infeksi kulit, anemia, kecemasan, asma, komedo, bronkitis, radang selaput lendir pada hidung, dada sesak, koleran, luka, sakit kepala, demam, sariawan, kudis, iritasi, dan rematik (Susanti & Nurman, 2022). Tumbuhan ini berupa pohon dengan bentuk tegak lurus, menyebar, ataupun terkulai, memiliki batang yang bergaris, berkutil, bercak,

serta warna yang bervariasi seperti abu-abu, putih, cokelat susu, ataupun hijau. Menurut Kleden dkk., daun kelor umumnya berbentuk bulat telur dengan tepi daun rata, berukuran kecil-kecil, tersusun majemuk dalam satu tangkai, dan berwana hijau tua, hijau muda, hingga hijau kekuningan (Auliya dkk., 2018). Gambar 6 memperlihatkan bentuk tumbuhan kelor.



Gambar 6. Daun Kelor (Rahayu & Hasibuan, 2023).

2.2.7. Bidara (*Ziziphus mauritiana*)

Bidara (*Ziziphus mauritiana*) merupakan salah satu tumbuhan berkhasiat obat yang memiliki berbagai manfaat dalam kehidupan sehari-hari. Berdasarkan penelitian yang dilakukan oleh Ardinimia dan rekan-rekannya pada tahun 2023, daun bidara berfungsi sebagai antioksidan yang mampu menetralisir dan mencegah kerusakan sel akibat radikal bebas. Dalam perannya sebagai antikanker, daun bidara dapat berfungsi sebagai reseptor obat antikanker yang mampu menghambat pertumbuhan sel kanker. Daun bidara juga memiliki aktivitas antibakteri yang efektif dalam menghambat pertumbuhan berbagai bakteri *E-coli*. Dalam penggunaanya sebagai antidiare, ekstrak daun bidara dapat memberikan efektivitas antidiare paling efektif (Ardinimia dkk., 2023). Tumbuhan ini berupa pohon yang

tingginya dapat mencapai 1.5 meter dan tumbuh tegak atau menyebar dengan cabang-cabang yang menjuntai. Tumbuhan ini memiliki duri yang tumbuh pada ranting-ranting yang bercabang secara acak. Daunnya berbentuk bulat telur dengan sifat selalu hijau atau setengah meranggas, menjadikannya tumbuhan yang tahan terhadap berbagai kondisi lingkungan. Bidara merupakan tumbuhan lengkap yang memiliki bunga, buah, batang, akar dan daun (Raharjeng & Masliyah, 2020). Bentuk tumbuhan bidara dapat dilihat pada Gambar 7.



Gambar 7. Daun Bidara (Ardinimia dkk., 2023).

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

Cincau hijau (*Cyclea barbata L. Miers*) merupakan tumbuhan yang dikenal sebagai bahan minuman dan memiliki manfaat dalam pengobatan tradisional. Berdasarkan Keputusan Menteri Kesehatan Republik Indonesia Nomor HK.01.07/MENKES/187/2017 tentang Formularium Ramuan Obat Tradisional Indonesia, daun cincau dapat dimanfaatkan sebagai obat untuk panas dalam (Kementerian Kesehatan Republik Indonesia, 2017). Selain itu, daun cincau juga bermanfaat untuk mengatasi sakit perut, demam, maag, dan hipertensi. Cincau merupakan tumbuhan merambat yang panjangnya dapat mencapai 10 meter, dengan batang lunak dan berduri di bagian kulit. Daunnya

berbentuk seperti perisai dengan tepi yang rata, bergerigi atau berombak. Bunganya berwarna kuning kehijauan hingga kuning muda, dan buahnya merupakan buah batu berwarna merah. Biji cincau berbentuk bulat telur dan keras (Fathaddin dkk., 2022). Bentuk daun cincau dapat dilihat pada Gambar 8.



Gambar 8. Daun Cincau Hijau (Lathifah, 2024).

2.2.9. Sambung Nyawa (*Gynura procumbens*)

Sambung nyawa (*Gynura procumbens*) adalah tumbuhan yang banyak dimanfaatkan dalam pengobatan tradisional karena berbagai khasiatnya. Berdasarkan Keputusan Menteri Kesehatan Republik Indonesia Nomor HK.01.07/MENKES/187/2017 tentang Formularium Ramuan Obat Tradisional Indonesia, daun sambung nyawa dapat dimanfaatkan sebagai obat untuk mata ikan (Kementerian Kesehatan Republik Indonesia, 2017). Selain itu, daun sambung nyawa juga berkhasiat sebagai antidiabetes dan antihipertensi. Tumbuhan ini berperawakan herba yang memanjang, rebah atau merayap dengan tinggi mencapai 0,5-1 meter. Batangnya bersudut, beralur memanjang, lunak, dan berwarna hijau dengan pola ungu. Daun sambung nyawa berbentuk tunggal, tersebar, dan bervariasi antara bentuk bulat telur hingga lanset, dengan tepi yang rata,

bergelombang atau bergigi. Ukuran daun berkisar antara panjang 3,5-12,5 cm dan lebar 1-5,5 cm, dengan kedua permukaan yang berambut halus (Kementerian Kesehatan Republik Indonesia, 2015). Gambar 9 memperlihatkan bentuk daun sambung nyawa.



Gambar 9. Daun Sambung Nyawa (Dinas Pertanian Kabupaten Buleleng, 2019).

2.2.10. Ketapang (*Terminalia catappa*)

Ketapang (*Terminalia catappa*) merupakan pohon multifungsi yang sering dimanfaatkan sebagai tanaman obat tradisional untuk mengatasi berbagai penyakit. Dalam pengobatan tradisional, ketapang dikenal memiliki khasiat untuk meredakan gangguan kardiovaskuler, penyakit kulit, masalah liver, gangguan pernapasan, masalah pencernaan, infeksi gonore, serta insomnia. Tumbuhan ini berupa pohon dengan ketinggian mencapai 10-35 meter (Mayarlis & Chatri, 2024). Batangnya tumbus lurus secara vertikal, sementara cabang-cabangnya tumbuh horizontal dalam susunan bertingkat (Ningrum, 2021). Daun ketapang berbentuk bulat telur dengan ujung yang membulat dan pangkal yang runcing. Tepi daun berombang, dan tulang daunnya tersusun sejajar. Daun ketapang memiliki ukuran panjang antara 10-32 cm dan lebar 3-11 cm, dengan permukaan yang

mengilap berwarna hijau tua. Pada musim kemarau atau musim gugur, warna daun ketapang berubah menjadi kuning kecoklatan atau cokelat kemerahan, sebagai akibat dari kurangnya kandungan klorofil yang memberikan warna hijau pada daun (Latifa, 2020). Bentuk daun ketapang dapat dilihat pada Gambar 10.



Gambar 10. Daun Ketapang (Rangkuti, 2024).

2.3. *Deep Learning*

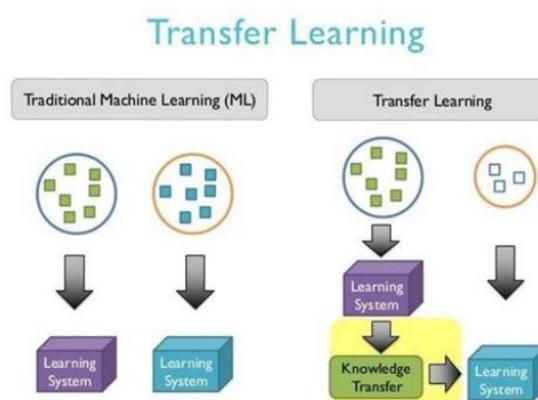
Deep learning merupakan turunan dari *artificial intelligence* yang banyak digunakan dalam pemrosesan gambar atau citra digital. Metode ini dirancang untuk menganalisis data secara terus-menerus, menyerupai cara kerja otak manusia dalam membuat keputusan (Peryanto dkk., 2019). Berbeda dengan *machine learning* yang memerlukan pemilihan fitur sebelumnya, *deep learning* dapat secara otomatis mengekstrak fitur dari data mentah, seperti gambar atau suara, tanpa perlu campur tangan manusia.

Deep learning memanfaatkan algoritma *artificial neural network* (ANN), yang terinspirasi dari struktur jaringan biologis pada otak manusia. Jaringan saraf tiruan ini adalah representasi buatan dari otak manusia yang dirancang untuk mensimulasikan proses pembelajaran otak (Andini, 2023). Jaringan ini terdiri dari beberapa lapisan neuron yang saling terhubung, dan setiap neuron berfungsi untuk memproses informasi. Dengan ANN, sistem dapat belajar

dari data yang diberikan dan menemukan pola yang lebih kompleks dengan mengubah hubungan antar neuron berdasarkan pengalaman yang didapat. Dengan cara ini, *deep learning* bisa melakukan analisis yang lebih canggih dan digunakan dalam berbagai bidang, seperti pengenalan wajah, pemrosesan bahasa, dan pengembangan kendaraan otonom (LeCun dkk., 2015).

2.4. *Transfer Learning*

Transfer learning adalah teknik dalam *machine learning* yang memanfaatkan pengetahuan dari suatu masalah sebelumnya untuk menyelesaikan masalah lain yang serupa (Chougule dkk., 2022). Model *transfer learning* biasanya dilatih pada *dataset* berukuran besar seperti *ImageNet*, dan bobot yang diperoleh dari *pre-trained model* dapat digunakan pada *dataset* baru (Nusantoro dkk., 2022). Salah satu contoh *transfer learning* yaitu menggunakan *model pre-trained* yang dilatih untuk mengenali mobil, kemudian model tersebut dimanfaatkan untuk mengenali truk (Wijaya dkk., 2021). Ilustrasi terkait proses *transfer learning* dan perbedaanya dengan *machine learning* tradisional dapat dilihat pada Gambar 11.



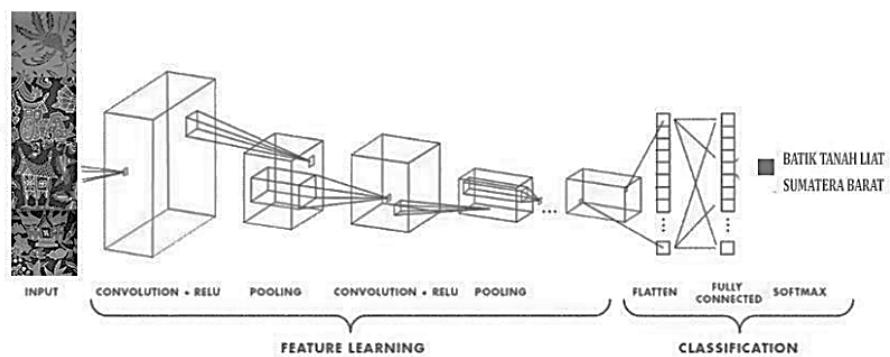
Gambar 11. *Transfer Learning* (Wijaya dkk., 2021).

Secara umum, alur dalam implementasi *transfer learning* terdiri dari beberapa langkah. Pertama, mengambil lapisan-lapisan dari *pre-trained model*. Kedua, membekukan (*freeze*) lapisan-lapisan tersebut untuk mencegah hilangnya

informasi selama proses pelatihan. Ketiga, menambahkan atau memodifikasi beberapa lapisan baru di atas lapisan yang telah dibekukan, sehingga model dapat menyesuaikan fitur yang sudah ada untuk membuat prediksi pada *dataset* baru. Terakhir, melatih lapisan baru menggunakan *dataset* yang tersedia (Wijaya dkk., 2021).

2.5. *Convolutional Neural Network (CNN)*

Convolutional Neural Network (CNN) adalah salah satu algoritma dalam *deep learning* yang dirancang khusus untuk mengolah data dua dimensi, seperti gambar (Pujiati & Rochmawati, 2022). CNN memiliki kemampuan untuk mengenali pola-pola visual dalam gambar, seperti tepi, tekstur, atau bentuk, sehingga sangat efektif untuk tugas-tugas seperti klasifikasi gambar, deteksi objek, dan segmentasi citra. CNN bekerja secara bertahap dengan pendekatan hierarkis, di mana *output* dari satu lapisan digunakan sebagai *input* untuk lapisan berikutnya (Mujahid dkk., 2024). Arsitektur CNN terdiri dari 2 lapisan utama, yaitu *feature learning* dan *classification layer*, seperti yang ditunjukkan pada Gambar 12.



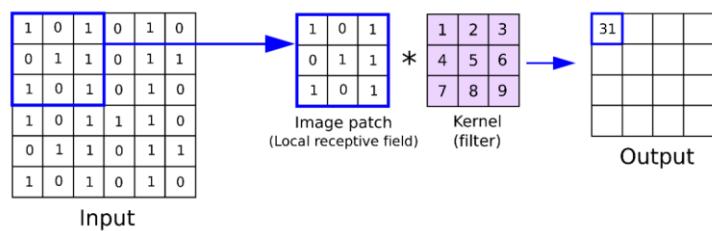
Gambar 12. Arsitektur CNN (Azmi dkk., 2023).

Pada bagian *feature learning*, terdapat lapisan yang langsung menerima *input* berupa gambar dan memprosesnya hingga menghasilkan data berupa fitur penting dari gambar tersebut. Proses ini melibatkan *convolutional layer* dan

pooling layer, yang masing-masing menghasilkan *feature maps* berupa angka-angka yang mewakili gambar. Hasil dari proses ini kemudian diteruskan ke bagian klasifikasi. Pada *classification layer*, terdapat beberapa lapisan yang saling terhubung penuh (*fully connected*). Lapisan ini menerima *feature maps* dari proses *feature learning* sebagai *input*. Data tersebut kemudian diproses melalui *flatten layer* dengan tambahan beberapa *hidden layers* pada lapisan *fully connected*, hingga menghasilkan *output* akhir berupa nilai akurasi klasifikasi untuk setiap kelas (Azmi dkk., 2023).

2.5.1. Convolutional Layer (Conv. Layer)

Convolutional layer adalah komponen utama dalam arsitektur CNN yang bertugas untuk mengekstraksi fitur penting dari *input*, seperti pola tepi, tekstur, atau bentuk pada gambar. Lapisan ini terdiri dari sejumlah *neuron* yang diatur membentuk *filter* dengan dimensi tertentu berupa panjang dan tinggi (piksel) (Azmi dkk., 2023). *Filter-filter* ini diinisialisasi secara acak dan melakukan operasi konvolusi untuk mengekstraksi fitur serta mempelajari representasi fitur dari gambar *input* (Muhammad & Wibowo, 2021). Proses konvolusi dilakukan dengan menggeser *filter* ke seluruh area gambar dan menghasilkan *output* berupa *feature map* yang merepresentasikan pola-pola yang terdeteksi. *Feature map* ini kemudian diteruskan ke lapisan selanjutnya untuk pemrosesan lebih lanjut. Gambaran proses konvolusi dapat dilihat pada Gambar 13.



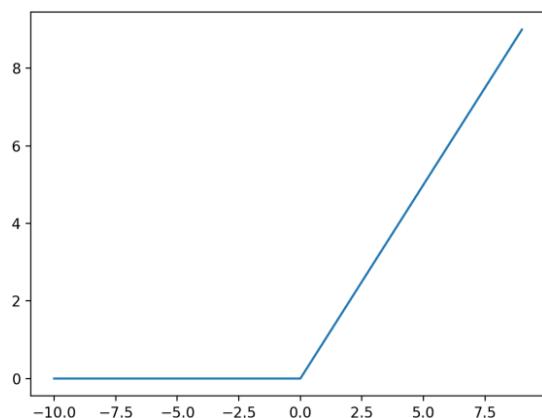
Gambar 13. Proses konvolusi (Muhammad & Wibowo, 2021).

2.5.2. Fungsi Aktivasi *SiLU*

Fungsi aktivasi *SiLU* (*Sigmoid Linear Unit*) merupakan fungsi non-linear yang menggabungkan karakteristik dari fungsi linear dan sigmoid. Fungsi ini mengalikan input x terhadap fungsi aktivasi sigmoid (Taupik dkk., 2021). Fungsi aktivasi SiLu dirumuskan pada Persamaan (1).

2.5.3. Fungsi Aktivasi *ReLU*

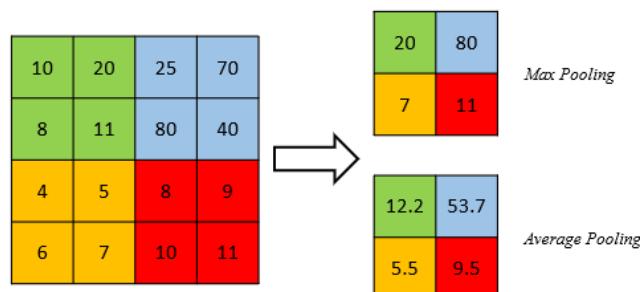
Fungsi aktivasi ReLU (*Rectified Linear Unit*) merupakan fungsi non-linear yang paling umum digunakan dalam arsitektur CNN. Fungsi ini bekerja dengan cara mengubah nilai *input* x menjadi *output* $f(x)$ yang bernilai nol jika $x \leq 0$, dan sama dengan x jika $x > 0$ (Firmansyah & Hayadi, 2022). Fungsi aktivasi ReLU dirumuskan pada Persamaan (2) dan divisualisasikan pada Gambar 14.



Gambar 14. Grafik fungsi aktivasi ReLU (Purwitasari & Soleh, 2022).

2.5.4. *Pooling Layer*

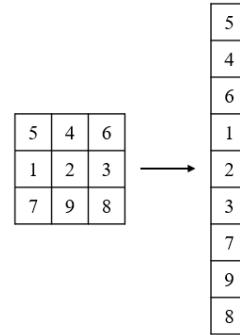
Pooling layer adalah *layer* dalam arsitektur CNN yang berfungsi untuk mereduksi dimensi *feature map* tanpa menghilangkan informasi penting. Proses ini membantu mengurangi kompleksitas komputasi, meningkatkan efisiensi, serta mengurangi resiko *overfitting*. Jenis *pooling layer* yang sering digunakan ialah *max pooling* dan *average pooling*. Pada *max pooling*, nilai yang dipilih adalah nilai terbesar dalam area yang diproses, sedangkan pada *average pooling*, nilai yang diambil merupakan rata-rata dari nilai-nilai dalam area tersebut (Setyawan dkk., 2023). Ilustrasi *layer* yang dihasilkan pada *pooling layer* dapat dilihat pada Gambar 15.



Gambar 15. Ilustrasi proses pada *pooling layer* (Zafar dkk., 2022).

2.5.5. *Flatten Layer*

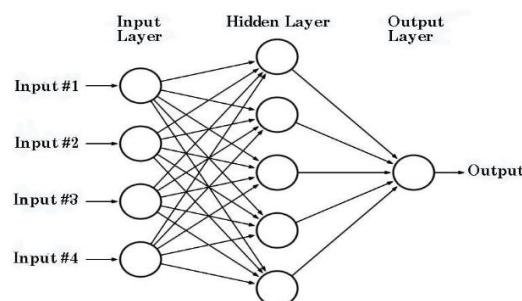
Flatten layer adalah lapisan dalam CNN yang bertugas untuk mengubah nilai masukan dari *pooling layer* menjadi bentuk satu dimensi (Muhammad & Wibowo, 2021). Setiap hasil dari proses *pooling* diubah ke dalam bentuk vektor satu dimensi agar dapat diproses lebih lanjut oleh *fully connected layer* untuk keperluan klasifikasi. Lapisan ini menjadi penghubung antara proses ekstraksi fitur dengan proses klasifikasi. Ilustrasi proses ini dapat dilihat pada Gambar 16.



Gambar 16. Ilustrasi proses pada *flatten layer* (Suriya dkk., 2019).

2.5.6. *Fully Connected Layer (FC. Layer)*

Fully connected layer adalah lapisan akhir dalam arsitektur CNN yang berfungsi sebagai *multi-layer perception* (MLP). Lapisan ini menghubungkan setiap *neuron* di satu lapisan dengan *neuron* di lapisan berikutnya secara penuh (Muhammad & Wibowo, 2021). *Fully connected layer* bertugas untuk membuat keputusan atau prediksi berdasarkan proses yang telah dilakukan pada *hidden layers*. Keputusan atau prediksi yang dihasilkan pada *fully connected layer* dilakukan dengan mengaplikasikan bobot yang telah ditentukan pada setiap elemen dalam vektor *input*. Bobot ini berfungsi untuk memberikan kontribusi relating dari setiap fitur yang telah diekstraksi sebelumnya terhadap hasil klasifikasi. Ilustrasi dari *fully connected layer* dapat dilihat pada Gambar 17.

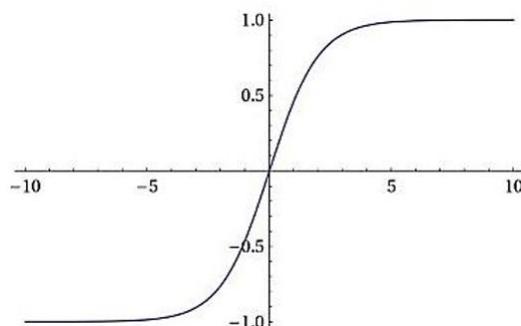


Gambar 17. Ilustrasi proses pada *fully connected layer* (Azmi dkk., 2023)

2.5.7. Fungsi Aktivasi *Softmax*

Fungsi *softmax* merupakan fungsi aktivasi yang digunakan pada *output layer* dalam model klasifikasi multi-kelas. Fungsi ini menghitung probabilitas untuk setiap kelas, sehingga hasil prediksi akan mengarah pada kelas dengan nilai probabilitas tertinggi (Purwitasari & Soleh, 2022). *Output* yang dihasilkan dari fungsi ini mempunyai nilai probabilitas antara 0 hingga 1. Fungsi aktivasi *softmax* dirumuskan pada Persamaan (3) dan divisualisasikan pada Gambar 18.

$$f(x) = \frac{e^{xi}}{\sum_{j=0}^k e^{xj}} \dots \quad (3)$$



Gambar 18. Grafik fungsi aktivasi *softmax* (Purwitasari & Soleh, 2022).

2.6. EfficientNetV2B0

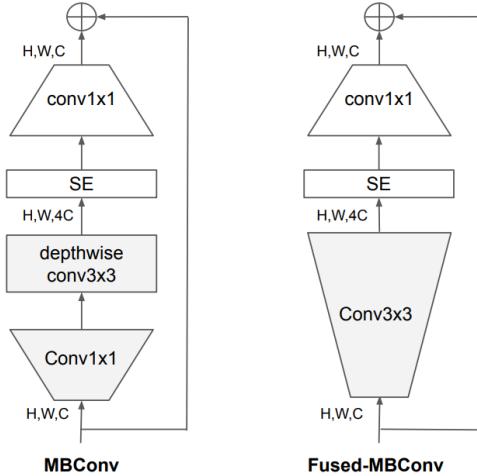
EfficientNetV2B0 adalah salah satu arsitektur *convolutional neural network* (CNN) dalam keluarga *EfficientNet* yang dirancang untuk tugas klasifikasi citra. Arsitektur ini diperkenalkan oleh Mingxing Tan dan Quoc V. Le pada tahun 2021 sebagai pengembangan dari *EfficientNet* versi sebelumnya (Tan & Le, 2021). Struktur dasar dari arsitektur *EfficientNetV2B0* dapat dilihat pada Gambar 19.

Stage	Operator	Stride	#Channels	#Layers
0	Conv3x3	2	24	1
1	Fused-MBConv1, k3x3	1	24	2
2	Fused-MBConv4, k3x3	2	48	4
3	Fused-MBConv4, k3x3	2	64	4
4	MBConv4, k3x3, SE0.25	2	128	6
5	MBConv6, k3x3, SE0.25	1	160	9
6	MBConv6, k3x3, SE0.25	2	256	15
7	Conv1x1 & Pooling & FC	-	1280	1

Gambar 19. Arsitektur *EfficientNetV2* (Tan & Le, 2021).

Blok utama yang digunakan dalam arsitektur *EfficientNetV2B0* adalah *MBConv* dan *Fused-MBConv*. *MBConv* (*Mobile Inverted Bottleneck Convolution*) merupakan jenis blok konvolusi yang menggunakan pendekatan *depthwise separable convolution*, yaitu memisahkan proses konvolusi menjadi dua langkah: *depthwise convolution* dan *pointwise convolution* (Chollet, 2016). Blok *MBConv* terdiri atas urutan konvolusi 1x1 untuk memperluas dimensi fitur (*expand layer*), diikuti *depthwise convolution* untuk mengekstraksi fitur spasial, lalu *pointwise convolution* atau konvolusi 1x1 untuk mengembalikan dimensi semula (Tan & Le, 2021). Selain itu, blok ini juga dilengkapi dengan *skip connection* dan *Squeeze-and-Excitation* (SE) untuk menyesuaikan bobot antar *channel* dan meningkatkan representasi fitur.

Sementara itu, *Fused-MBConv* adalah varian blok lain yang digunakan pada tahap awal (*early stage*) dari arsitektur *EfficientNetV2*. Blok ini menggantikan *depthwise separable convolution* dengan konvolusi standar 3x3 untuk menyederhanakan struktur dan mempercepat proses *training*. *Fused-MBConv* terdiri dari konvolusi 1x1 untuk memperluas dimensi fitur (*expand layer*), diikuti konvolusi standar 3x3, serta dilengkapi dengan *skip connection* dan *Squeeze-and-Excitation* (SE). Desain ini terbukti lebih cepat dilatih dan lebih efisien pada tahap awal pemrosesan fitur citra (Tan & Le, 2021). Ilustrasi perbandingan struktur blok *MBConv* dan *Fused-MBConv* dapat dilihat pada Gambar 20.



Gambar 20. Struktur dari *MBConv* dan *Fused-MBConv* (Tan & Le, 2021).

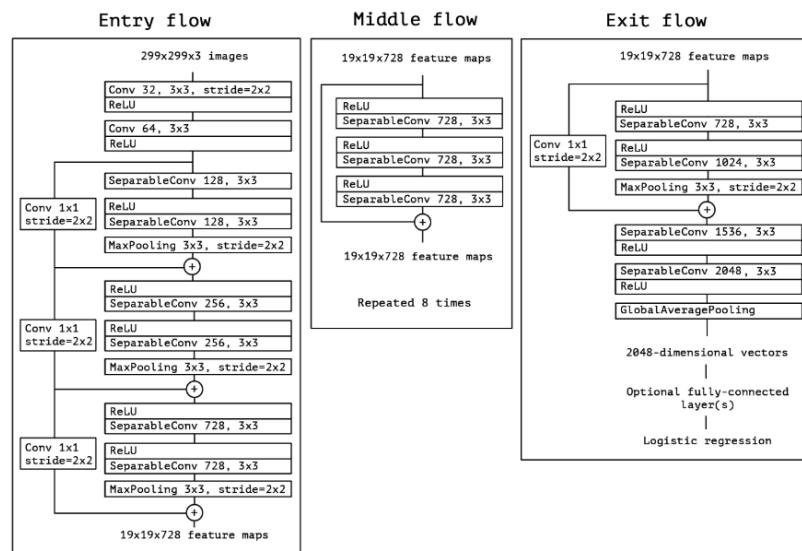
Pada *EfficientNetV1* (2019), Tan & Le memperkenalkan pendekatan *compound scaling*, yaitu metode penskalaan model dengan cara meningkatkan *depth*, *width*, *input resolution* secara proporsional menggunakan satu koefisien skala tunggal, yaitu φ (Tan & Le, 2019). Namun, pada *EfficientNetV2*, pendekatan *compound scaling* ini tidak lagi digunakan. Sebagai gantinya, diterapkan *non-uniform scaling*, yaitu penskalaan yang tidak dilakukan secara seragam (). Artinya, komponen-komponen jaringan seperti kedalaman dan lebar dapat ditingkatkan secara berbeda-beda sesuai kebutuhan. Pendekatan ini merupakan hasil dari *training-aware neural architecture search* (NAS) dan berbagai eksperimen yang bertujuan untuk mempercepat proses *training* tanpa mengorbankan akurasi (Tan & Le, 2021).

2.7. *Xception*

Xception adalah arsitektur jaringan saraf tiruan yang dikembangkan oleh Francois Chollet pada tahun 2017 sebagai pengembangan lebih lanjut dari model *Inception*. Arsitektur ini mengadopsi konsep *depthwise separable convolutions*, yang memisahkan proses konvolusi menjadi dua langkah utama, yaitu *depthwise convolution* dan *pointwise convolution* (Chollet, 2016). *Depthwise convolution* adalah konvolusi yang dilakukan pada setiap

saluran input secara terpisah, sedangkan *pointwise convolution* digunakan untuk menggabungkan hasil dari setiap saluran tersebut (Fajrina dkk., 2024).

Arsitektur dari jaringan *Xception* diilustrasikan pada Gambar 21. Pada arsitektur *Xception*, data pertama-tama akan melewati *entry flow*, kemudian melalui *middle flow* yang diulang sebanyak delapan kali, dan akhirnya melalui *exit flow* (Chollet, 2016). Proses ini memungkinkan jaringan untuk mempelajari fitur yang lebih kompleks secara efisien, dengan memanfaatkan *depthwise separable convolutions* yang mengurangi jumlah parameter dan mempercepat waktu pelatihan, sehingga meningkatkan performa model secara keseluruhan.



Gambar 21. Arsitektur *Xception* (Chollet, 2016).

2.8. Dataset

Dataset adalah kumpulan data yang digunakan untuk melatih, menguji, dan mengevaluasi model dalam *machine learning* atau *deep learning*. *Dataset* dapat berupa gambar, suara, video, teks, atau bentuk data lainnya yang sesuai dengan tugas yang akan diselesaikan oleh model. Dalam *machine learning* atau *deep learning*, *dataset* umumnya dibagi menjadi tiga bagian, yaitu *data training*, *data validation*, dan *data testing*. *Data training* digunakan untuk

melatih model, *data validation* digunakan untuk menguji data baru guna memastikan hasil pembelajaran dari tahap pelatihan sudah sesuai (Putra dkk., 2024). *Data testing* digunakan untuk menguji kinerja akhir model setelah dilatih. *Dataset* dapat diperoleh dari berbagai sumber, seperti *dataset public* (*Kaggle*, *Earth Data*, *Google Dataset Search*) ataupun *dataset private* (data internal, penelitian) (Kiranti, 2023).

2.9. *Preprocessing*

Preprocessing merupakan tahap pengolahan *dataset* yang dilakukan sebelum memulai proses *modelling* (Setyawan dkk., 2023). Tujuan utama dari *preprocessing* adalah untuk memastikan bahwa data yang berada dalam kondisi yang baik, bersih, dan siap untuk dianalisis. Proses ini sangat krusial karena data mentah sering kali mengandung noise, duplikasi, atau ketidakkonsistenan yang dapat memengaruhi kinerja model.

Tahapan *preprocessing* melibatkan beberapa teknik, seperti pembersihan data, normalisasi, *scaling*, *feature extraction*, dan reduksi dimensi. Langkah-langkah ini membantu mengubah data menjadi bentuk yang siap digunakan oleh model (Alghifari & Juardi, 2021). Dengan *preprocessing* yang tepat, data yang diberikan kepada model menjadi lengkap, konsisten, dan dalam format yang tepat untuk menghasilkan prediksi yang lebih akurat.

2.9.1. *Resize*

Resize merupakan proses mengubah ukuran gambar ke dimensi tertentu tanpa mengeleminasi fitur penting dari gambar. Tujuan utama dari proses ini adalah untuk menyamakan ukuran seluruh citra agar sesuai dengan kebutuhan arsitektur model yang digunakan (Novalina & Rizkinia, 2023). Selain itu, tujuan lainnya untuk mempercepat waktu komputasi selama proses *training* (Putra dkk., 2024).

2.9.2. Normalisasi

Normalisasi atau *rescaling* adalah proses mengubah nilai piksel gambar ke dalam rentang tertentu, biasanya antara 0 hingga 1 atau -1 hingga 1. Proses ini dilakukan dengan membagi setiap nilai piksel dengan nilai maksimum piksel. Tujuan dari normalisasi ini adalah untuk mengurangi skala nilai piksel agar lebih mudah diproses oleh model (Fajrina dkk., 2024).

2.10. *Training Model*

Training model adalah tahapan di mana model yang telah dibuat akan belajar mengenali ciri atau karakteristik dari data yang dilatih (Setyawan dkk., 2023). Pada tahap ini, model menggunakan data latih untuk mempelajari pola-pola yang ada, sehingga dapat menghasilkan prediksi yang akurat saat dihadapkan pada data uji. Pada tahap ini ada dua proses utama, yaitu *feed-forward* dan *backpropagation*. Pada *feed-forward*, data yang di-*input*-kan akan diproses dalam model untuk menghasilkan *output* atau prediksi. Data ini melewati beberapa lapisan dalam model untuk menghasilkan *output*. Setelah itu, pada *backpropagation*, model menghitung kesalahan antara hasil yang diprediksi dan hasil yang seharusnya. Kemudian, kesalahan ini digunakan untuk memperbaiki model agar lebih akurat. Proses tersebut diulang beberapa kali hingga model memberikan hasil yang tepat. Selain itu, dalam *training model*, pemilihan *hyperparameter* juga memegang peranan penting. *Hyperparameter* adalah parameter yang tidak dipelajari langsung selama proses *training*, melainkan diatur sebelum pelatihan dimulai (Fajrina dkk., 2024). Contoh *hyperparameter* diantaranya adalah *optimizer*, *learning rate*, *epoch*, dan *batch size* (Fajrina dkk., 2024).

2.10.1. *Optimizer*

Optimizer adalah algoritma yang diterapkan dalam proses *training model* untuk menemukan dan memperbaiki nilai bobot serta bias dalam jaringan saraf (Fajrina dkk., 2024). Algoritma ini berperan penting dalam memperbaiki kinerja model dengan cara meminimalkan *loss function*, yaitu fungsi yang mengukur seberapa besar kesalahan prediksi yang dihasilkan oleh model (Wibawa, 2016). Dengan meminimalkan nilai *loss function*, *optimizer* dapat membantu model untuk mencapai hasil yang lebih akurat dan efektif dalam mengenali pola dalam data yang dilatih.

2.10.2. *Learning Rate*

Learning rate adalah salah satu *hyperparameter* yang penting dalam proses *training model*. *Learning rate* mengatur sejauh mana bobot jaringan diperbarui pada setiap iterasi selama proses *training* (Fajrina dkk., 2024). Pemilihan nilai *learning rate* yang tepat sangat penting untuk memastikan proses *training* berjalan efektif dan efisien, karena nilai yang terlalu kecil dapat membuat proses *training* berjalan sangat lambat, sementara nilai yang terlalu besar dapat menyebabkan model kesulitan untuk mencapai hasil optimal (Suhendra & Saputra, 2020).

2.10.3. *Epoch*

Epoch adalah satu kali siklus *training* dimana model memproses seluruh data latih dan memperbarui bobot serta bias (Wibawa, 2016). Setiap kali data digunakan untuk memperbarui model, itu dianggap satu *epoch*. Jumlah *epoch* yang digunakan dapat berbeda-beda, tergantung pada tingkat kesulitan tugas dan ukuran *dataset*. Jika

jumlah *epoch* terlalu banyak, model dapat mengalami *overfitting*. Sebaliknya, jika jumlah *epoch* terlalu sedikit, model dapat mengalami *underfitting* (Fajrina dkk., 2024).

2.10.4. *Batch Size*

Batch size adalah jumlah data yang diproses sekaligus dalam satu langkah *training model*. *Batch size* digunakan untuk membagi *dataset* menjadi kelompok-kelompok kecil yang disebut “*batch*”, sehingga tidak semua data diproses sekaligus. *Batch size* menentukan jumlah data yang diproses dalam setiap iterasi (*epoch*) selama *training model* (Fajrina dkk., 2024).

2.10.5. *Early Stopping*

Early stopping merupakan teknik yang digunakan untuk mencegah *overfitting*. Teknik ini dianggap efektif karena dapat menghentikan proses *training* ketika model telah mencapai performa optimal. Performa model dievaluasi pada data validasi di setiap *epoch*. Cara kerja *early stopping* adalah dengan menetapkan pemicu yang akan aktif jika kondisi tertentu terpenuhi. Beberapa parameter penting dalam *early stopping* antara lain, *patience*, *monitor*, dan *mode* (Surya dkk., 2025). *Patience* menunjukkan berapa banyak *epoch* yang diperbolehkan berjalan tanpa adanya peningkatan performa sebelum proses *training* dihentikan. Lalu, *monitor* adalah metrik yang diamati selama proses *training* untuk menilai apakah performa model mengalami peningkatan. Sementara itu, *mode* berfungsi untuk menentukan apakah metrik yang dipantau perlu dimaksimalkan atau diminimalkan (Surya dkk., 2025).

2.11. Confusion Matrix

Confusion matrix adalah metode yang digunakan untuk mengevaluasi kinerja sebuah model klasifikasi. Matriks ini memberikan gambaran tentang seberapa baik model dalam mengklasifikasikan data ke dalam kategori benar. *Confusion matrix* memiliki empat metrik utama untuk evaluasi, yaitu *true positive* (TP), *true negative* (TN), *false positive* (FP) dan *false negative* (FN) (Maxwell dkk., 2021). *Confusion matrix* dapat dilihat pada Gambar 22.

- | | |
|----------------------------|--|
| <i>True Positive</i> (TP) | = Kelas positif yang terprediksi sebagai kelas positif |
| <i>False Positive</i> (FP) | = Kelas positif yang terprediksi sebagai kelas negatif |
| <i>True Negative</i> (TN) | = Kelas negatif yang terprediksi sebagai kelas negatif |
| <i>False Negative</i> (FN) | = Kelas negatif yang terprediksi sebagai kelas positif |

Dalam *confusion matrix*, evaluasi kinerja dilakukan dengan menghitung akurasi, presisi, *recall*, dan *F1-score* berdasarkan empat metrik utama yang terdapat pada Gambar 22.

PREDICTED	ACTUAL									
	Clasess	A	B	C	D	E	F	G	H	I
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)

Gambar 22. *Confusion matrix* multi kelas (Kundu, 2022).

2.11.1. Akurasi

Akurasi adalah metrik yang digunakan untuk mengukur seberapa baik model dalam memprediksi kelas yang benar (Bekkar dkk., 2013). Akurasi dihitung dengan membandingkan *true positive* (TN) dengan total jumlah prediksi yang dilakukan oleh model. Semakin tinggi akurasi, semakin baik model dalam mengklasifikasikan data dengan benar. Persamaan akurasi dapat dilihat pada Persamaan (4) (Bekkar dkk., 2013).

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

2.11.2. Presisi

Presisi adalah metrik yang digunakan untuk mengukur seberapa banyak prediksi positif yang benar dibandingkan dengan seluruh prediksi positif yang dibuat oleh model. Dengan kata lain, presisi menunjukkan seberapa akurat model dalam memprediksi kelas positif (Bekkar dkk., 2013). Presisi dihitung dengan membagi jumlah prediksi *true positive* (TP) dengan jumlah prediksi *true positive* (TP) ditambah prediksi *false positive* (FP). Persamaan presisi dapat dilihat pada Persamaan (5) (Bekkar dkk., 2013).

2.11.3. *Recall*

Recall adalah metrik yang digunakan untuk mengukur seberapa baik model dalam menangkap semua kelas positif yang ada, yaitu seberapa banyak kelas positif yang berhasil dikenali dengan benar oleh model (Bekkar dkk., 2013). *Recall* dihitung dengan membagi jumlah prediksi *true positivie* (TP) dengan jumlah prediksi *true positive* (TP)

ditambah prediksi *false negative* (FN). Persamaan *recall* dapat dilihat pada Persamaan (6) (Bekkar dkk., 2013).

$$recall = \frac{TN}{TN+FN} \quad (6)$$

2.11.4. *F1-Score*

F1-score adalah metrik yang digunakan untuk mengukur kinerja model klasifikasi dengan menggabungkan presisi dan *recall* menjadi satu nilai. Ukuran ini sering digambarkan sebagai rata-rata harmonic antara presisi dan *recall* (Maxwell dkk., 2021). *F1-score* sering digunakan ketika ingin menyeimbangkan presisi dan *recall*, terutama ketika terdapat ketidakseimbangan antara kelas positif dan negatif dalam *dataset*. Persamaan *f1-score* dapat dilihat pada persamaan 7 (Maxwell dkk., 2021).

$$F1 score = 2 \times \frac{presisi \times recall}{presisi + recall} \quad \dots \quad (7)$$

2.12. *Streamlit*

Streamlit merupakan framework berbasis *python* yang bersifat *opensource* dan dirancang untuk mempermudah pengembangan aplikasi *web* di bidang *machine learning* dan *data science* (Marco, 2024). Keunggulan dari *framework* ini yaitu memungkinkan pengguna untuk membuat aplikasi *web* tanpa harus memiliki pengetahuan terkait *HTML*, *CSS* atau *Javascript*. Secara umum, *streamlit* menawarkan berbagai fitur lengkap yang dapat digunakan untuk mengontrol aplikasi *web*, seperti *slider*, *text input*, *checkbox*, *selectbox*, dan sebagainya (Agarwal, 2019).

2.13. *Black Box*

Black box testing merupakan metode pengujian kualitas perangkat lunak yang berfokus pada aspek fungsionalitas sistem (Wijaya & Astuti, 2021). Secara singkat, *black box* juga dapat diartikan sebagai pengujian yang hanya menguji bagian luar dari perangkat lunak. Metode ini dilakukan tanpa perlu melihat atau menguji *source code*, melainkan berfokus pada antarmuka sistem dengan hanya memperhatikan *input* dan *output*, tanpa mempertimbangkan struktural internal perangkat lunak (Pratama dkk., 2023). Pengujian ini dilakukan oleh tim penguji diluar dari tim pengembang perangkat lunak, sehingga hasil pengujian lebih objektif dan independen (Rachman dkk., 2023).

III. METODOLOGI PENELITIAN

3.1. Tempat dan Waktu Penelitian

3.1.1. Tempat Penelitian

Penelitian akan dilakukan di Laboratorium Rekayasa Perangkat Lunak, Jurusan Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung. Laboratorium ini beralamat di Jl. Prof. Dr. Sumantri Brojonegoro No. 1, Bandar Lampung, 35145, Indonesia.

3.1.2. Waktu Penelitian

Penelitian ini dilaksanakan pada tahun akademik 2024/2025 dimulai dari bulan November 2024 hingga bulan Mei 2025 yang dijelaskan secara *detail* pada Tabel 2.

Tabel 2. *Timeline* Penelitian.

Nama Kegiatan	2024				2025		
	Nov	Des	Jan	Feb	Mar	Apr	Mei
Pengumpulan <i>Dataset</i>							
<i>Preprocessing</i>							
<i>Modelling</i>							
<i>EfficientNetV2B0</i>							
<i>Modelling Xception</i>							
Evaluasi Model							
Pengembangan Sistem							
Penulisan Laporan							

3.2. Perangkat Penelitian

3.2.1. Perangkat Keras

Perangkat keras yang digunakan dalam penelitian ini adalah laptop dan kamera dengan detail sebagai berikut.

a. Laptop

Tipe	: VivoBook X415JA
Processor	: Core(TM) i3-1005G1
RAM	: 4,00 GB
Penyimpanan	: SSD 256 GB

b. Kamera

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

3.2.2. Perangkat Lunak

Perangkat lunak yang digunakan dalam proses penelitian ini adalah sebagai berikut.

- a. Sistem Operasi *Windows 11 Home Single Languange 64-bit* sebagai sistem operasi utama yang digunakan untuk menjalankan berbagai aplikasi dan perangkat lunak lainnya.
- b. *Google Drive* sebagai aplikasi untuk menyimpan *dataset*, file kode program, dan dokumen penelitian lainnya.
- c. *Google Colab* sebagai *platform* untuk pengkodean model *EfficienNetV2B0* dan *Xception* menggunakan bahasa pemrograman *Python*.

- d. *Visual Studio Code* versi 1.89.1 sebagai aplikasi atau *text editor* untuk mengembangkan aplikasi berbasis *web* dengan bahasa pemrograman *Python*.
- e. *Python* versi 3.12 dengan library *Tensorflow* dan *Streamlit* sebagai bahasa pemrograman dan *library* yang digunakan untuk mengembangkan aplikasi berbasis *web*.
- f. *Web Browser* sebagai alat untuk mengakses *Google Colab*, *Google Drive*, dan menguji aplikasi berbasis *web*.
- g. *Lucidspark* sebagai *platform* untuk pembuatan *United Model Languange (UML)*.

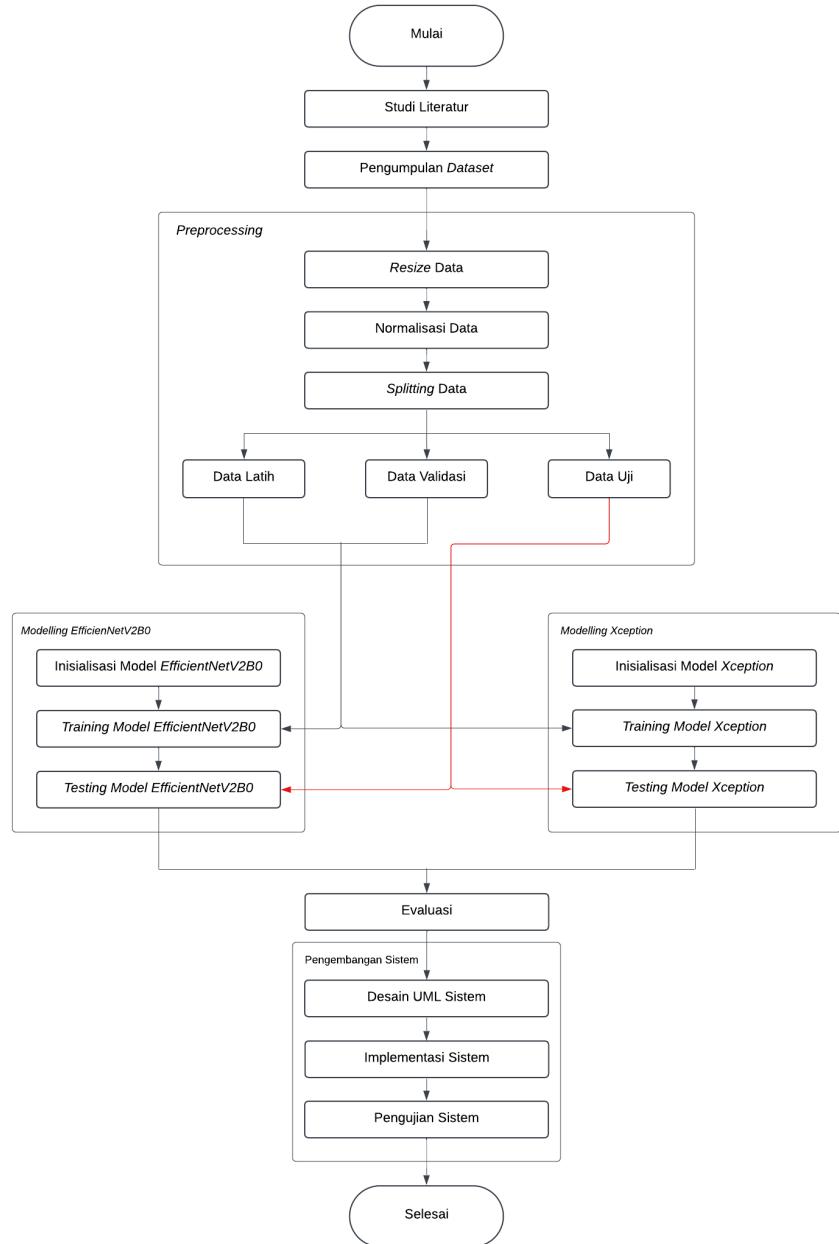
3.3. Tahap Penelitian

Penelitian ini akan dilakukan melalui beberapa tahapan, dimulai dari studi literatur, pengumpulan *dataset*, hingga *preprocessing* data. Tahapan *preprocessing* mencakup *resize data*, normalisasi data, dan *splitting data*. Setelah itu, tahap berikutnya adalah *modelling*, yang mencakup inisialisasi model, *training model*, dan *testing model*. Setelah tahap *modelling* selesai, akan dilakukan evaluasi untuk menentukan model terbaik antara *EfficientNetV2B0* dan *Xception*. Kedua model tersebut kemudian akan dikembangkan menjadi aplikasi berbasis *web*. Alur lengkap dari tahapan penelitian ini dapat dilihat pada Gambar 23.

3.3.1. Studi Literatur

Tahapan studi literatur dalam penelitian ini bertujuan untuk mengumpulkan informasi dan referensi yang relevan dengan topik yang diteliti. Pada tahap ini, dilakukan tinjauan terhadap berbagai penelitian terdahulu, buku, jurnal, artikel dan sumber lainnya yang membahas teori-teori yang mendukung penelitian ini, seperti

mengenai tumbuhan obat, *deep learning*, CNN, *EfficientNetV2B0*, *Xception*, dan hal-hal terkait lainnya.



Gambar 23. Tahap penelitian klasifikasi tumbuhan obat berdasarkan citra daun menggunakan arsitektur *EfficientNetV2BO* dan *Xception*.

3.3.2. Pengumpulan Dataset

Dataset yang digunakan pada penelitian ini terdiri dari dua jenis morfologi, yaitu jantung dan bulat telur. Dataset ini diperoleh dari dua sumber utama, yaitu penelitian terdahulu dan pengambilan data secara langsung. Data dari penelitian terdahulu terdiri dari citra daun tumbuhan sirih hijau (*Piper betle Linn*), binahong (*Anredera cordifolia*), dan kejibeling (*Serycocalyx crispus L*), dengan masing-masing tumbuhan memiliki 300 citra. Data yang diambil secara langsung mencakup 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*), yang masing-masing memiliki 300 citra untuk setiap tumbuhan. Tumbuhan obat yang daunnya memiliki morfologi jantung meliputi sirih hijau (*Piper betle Linn*), binahong (*Anredera cordifolia*), dan cincau hijau (*Cyclea barbata L. Miers*), sedangkan tumbuhan lainnya memiliki morfologi bulat telur. Total keseluruhan citra yang dikumpulkan adalah 3000 citra.

Daun-daun tumbuhan obat untuk *dataset* ini akan diambil dari Kota Bandar Lampung dan Kota Metro. Informasi rinci mengenai lokasi pengambilan setiap daun dapat dilihat pada Tabel 3. Proses pengambilan citra daun tumbuhan obat akan dilaksanakan di Jalan Raja Ratu, GG. Raja Ratu II, Labuhan Ratu, Kec. Kedaton, Kota Bandar Lampung. Pengambilan citra akan menggunakan kamera *Canon* dengan kertas HVS A4 sebagai latar belakangnya. Citra yang diambil akan berekstensi JPG atau JPEG, dan kemudian disimpan ke dalam *Google Drive* untuk mempermudah pemanggilan serta penggunaan data di *Google Colab*.

Tabel 3. Lokasi Pengambilan Data.

No	Nama Tumbuhan	Lokasi
1.	Bidara (<i>Ziziphus mauritiana</i>)	Jalan Dipo, Sumberrejo Sejahtera, Kec. Kemiling, Kota Bandar Lampung
2.	Kelor (<i>Moringa oleifera Lam</i>)	Jalan Pattimura, Sumberrejo Sejahtera, Kec. Kemiling, Kota Bandar Lampung
3.	Cincau Hijau (<i>Cyclea barbata L. Miers</i>)	Gang Sungkay, Hadimulyo Timur, Kec. Metro Pusat, Kota Metro
4.	Sambung Nyawa (<i>Gynura procumbens</i>)	Gang Sungkay, Hadimulyo Timur, Kec. Metro Pusat, Kota Metro
5.	Salam (<i>Eugenia polyantha Wight</i>)	Jalan Abdul Muis 9, Gedong Meneng, Kec. Rajabasa, Kota Bandar Lampung
6.	Pulai (<i>Alstonia scholaris</i>)	FMIPA Universitas Lampung, Gedong Meneng, Kec. Rajabasa, Kota Bandar Lampung
7.	Ketapang (<i>Terminalia 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

3.3.3. *Preprocessing*

Pada tahap *preprocessing*, data citra daun tumbuhan obat yang telah dikumpulkan akan dipersiapkan untuk digunakan dalam tahap *modelling*. *Preprocessing* yang akan dilakukan meliputi beberapa hal, yaitu *resize*, normalisasi data, dan *splitting data*.

a. *Resize Data*

Citra daun yang telah dikumpulkan kemudian akan diubah ukurannya (*resize*) dengan tujuan untuk menyamakan ukuran semua citra. Citra akan diubah menjadi ukuran 224×224 piksel. Pemilihan ukuran ini didasarkan pada ukuran input arsitektur *EfficientNetV2B0* dan penelitian sebelumnya yang dilakukan oleh

Novalina dan Rizkinia (2023). Proses resize ini akan dilakukan secara otomatis dengan bantuan library PIL (*Python Imaging Library*).

b. Normalisasi Data

Setelah itu, citra daun akan dinormalisasikan pada skala [-1, 1] sesuai dengan ketentuan normalisasi setiap arsitektur. Proses ini dilakukan dengan membagi nilai piksel gambar dengan 127.5, lalu menguranginya dengan 1.

c. *Splitting Data*

Tahapan terakhir dalam *preprocessing* adalah pembagian data (*splitting data*). *Dataset* yang digunakan berjumlah 3000 data dengan rincian yang ditampilkan pada Tabel 4. *Dataset* ini kemudian dibagi menjadi tiga bagian: data latih, data validasi, dan data uji. Pada penelitian ini digunakan dua skema pembagian data, yaitu:

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

Skema 80:10:10 digunakan sebagai konfigurasi utama yang mengacu pada penelitian Hani Cita Lestari (2023), yang menjadi rujukan utama dalam penelitian ini. Sementara itu, skema 70:20:10 digunakan sebagai perbandingan dan mengacu pada penelitian Mardiana dkk. (2023), yang menggunakan jumlah data hampir serupa, yaitu 3500 data dengan 10 kelas. Proses pembagian data akan dilakukan secara otomatis dengan bantuan modul ‘*train_test_split*’ dari *library scikit-learn*, yang memungkinkan pembagian data secara acak namun proporsional.

3.3.4. *Modeling EfficientNetV2B0*

Pada tahap modeling menggunakan arsitektur *EfficientNetV2B0*, data yang telah melalui tahap *preprocessing* akan digunakan sebagai input untuk melatih model. Proses *modeling* ini dilakukan secara bertahap, mencakup langkah-langkah berikut.

a. Inisialisasi Model

Pada langkah ini, arsitektur *EfficientNetV2B0* akan diinisialisasi menggunakan *library TensorFlow*. Model ini akan menggunakan *transfer learning*, dengan memodifikasi *layer output*, serta menambahkan *layer GlobalAveragePooling2D*, *Dropout*, dan *Dense(128)*. Arsitektur model secara keseluruhan dapat dilihat pada Gambar 24.

b. *Training Model*

Proses *training model* dengan arsitektur *EfficientNetV2B0* dilakukan menggunakan 2400 citra daun tumbuhan obat sebagai data latih. *Hyperparameter* yang digunakan dalam proses *training* dijelaskan secara rinci pada Tabel 4. Setelah proses pelatihan selesai, model yang dihasilkan akan disimpan dalam *file* berformat *h5* (.h5).

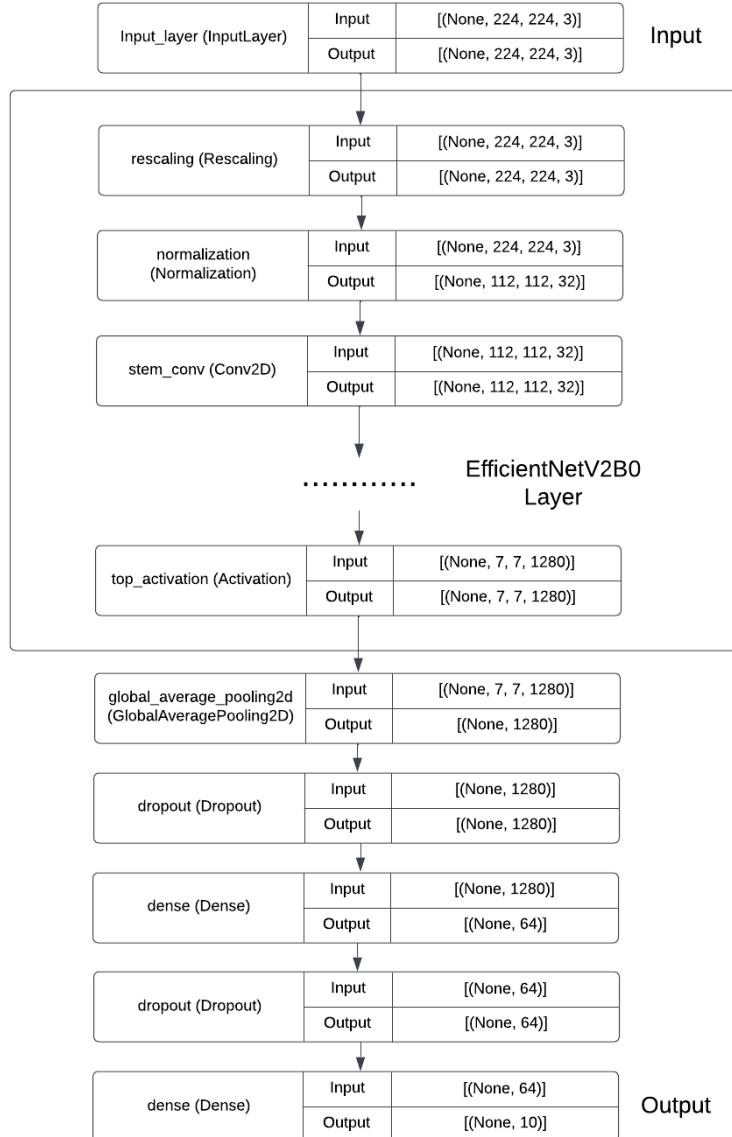
Tabel 4. Hyperparamater *training model EfficientNetV2B0*.

Nama Parameter	Nilai
<i>Input size</i>	$224 \times 224 \times 3$
<i>Batch size</i>	16
<i>Learning Rate</i>	0.001
<i>Epoch</i>	20
<i>Optimizer</i>	Adam

c. *Testing Model*

Setelah *training model* selesai, langkah selanjutnya adalah menguji kinerja model menggunakan data uji yang telah dipisahkan

sebelumnya pada tahap pembagian *dataset*. Proses pengujian ini akan mencakup evaluasi dengan *confusion matrix*.



Gambar 24. Arsitektur model *EfficientNetV2B0*.

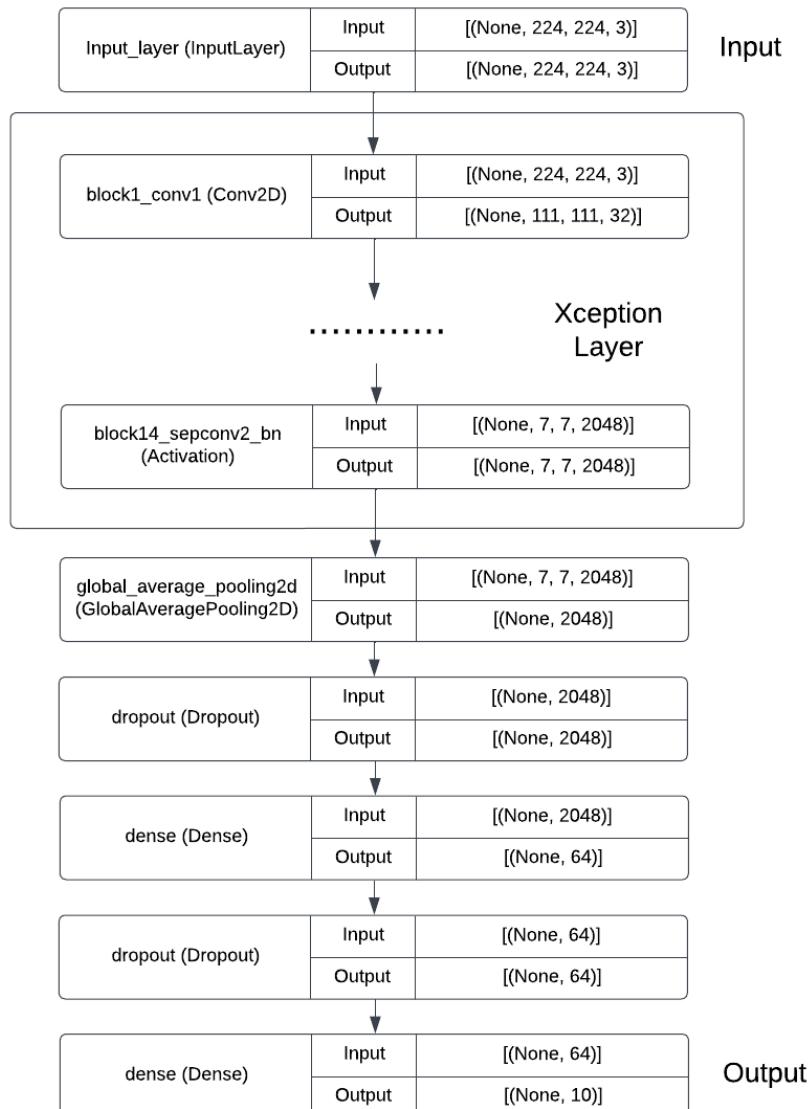
3.3.5. *Modelling Xception*

Pada tahap *modeling* menggunakan arsitektur *Xception*, data yang telah melalui tahap *preprocessing* akan digunakan sebagai input untuk

melatih model. Proses *modeling* ini dilakukan secara bertahap, mencakup langkah-langkah berikut.

a. Inisialisasi Model

Pada langkah ini, arsitektur *Xception* akan diinisialisasi menggunakan *library TensorFlow*. Model ini akan menggunakan *transfer learning*, dengan memodifikasi *layer output*, serta menambahkan *layer GlobalAveragePooling2D*, *Dropout*, dan *Dense(128)*. Arsitektur model secara keseluruhan dapat dilihat pada Gambar 25.



Gambar 25. Arsitektur model *Xception*.

b. Training Model

Proses *training model* dengan arsitektur *Xception* dilakukan menggunakan 2400 citra daun tumbuhan obat sebagai data latih. *Hyperparameter* yang digunakan dalam proses *training* dijelaskan secara rinci pada Tabel 5. Setelah proses pelatihan selesai, model yang dihasilkan akan disimpan dalam file berformat h5 (.h5).

Tabel 5. *Hyperparameter training model Xception.*

Nama Parameter	Nilai
<i>Input size</i>	$224 \times 224 \times 3$
<i>Batch size</i>	16
<i>Learning Rate</i>	0.001
<i>Epoch</i>	20
<i>Optimizer</i>	Adam

c. Testing Model

Setelah *training model* selesai, langkah selanjutnya adalah menguji kinerja model menggunakan data uji yang telah dipisahkan sebelumnya pada tahap pembagian *dataset*. Proses pengujian ini akan mencakup evaluasi dengan *confusion matrix*.

3.3.6. Evaluasi

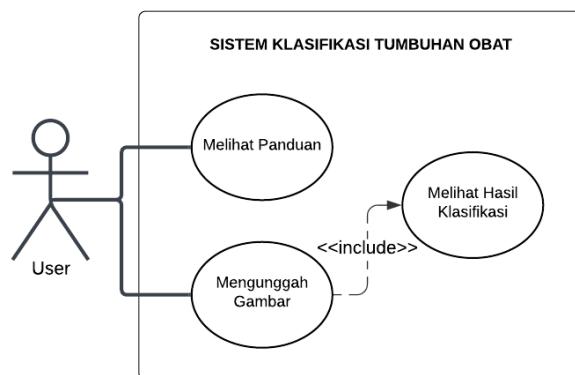
Pada tahap ini, hasil akurasi dan waktu eksekusi dari model *EfficientNetV2B0* dan *Xception* akan dibandingkan untuk menentukan model yang paling optimal.

3.3.7. Pengembangan Sistem

Pada tahap ini, hasil model *EfficientNetV2B0* dan *Xception* akan diimplementasikan ke dalam aplikasi berbasis *web*. Proses pengembangan sistem ini mencakup beberapa langkah, antara lain:

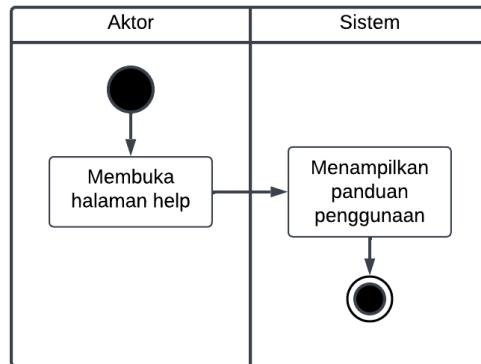
a. Desain *Unified Modeling Language* (UML)

Langkah pertama dalam pengembangan sistem ini adalah merancang dan menggambarkan alur sistem menggunakan *Unified Modeling Language* (UML). UML yang digunakan adalah *use case diagram* dan *activity diagram*. *Use case diagram* sistem ini dapat dilihat pada Gambar 26.

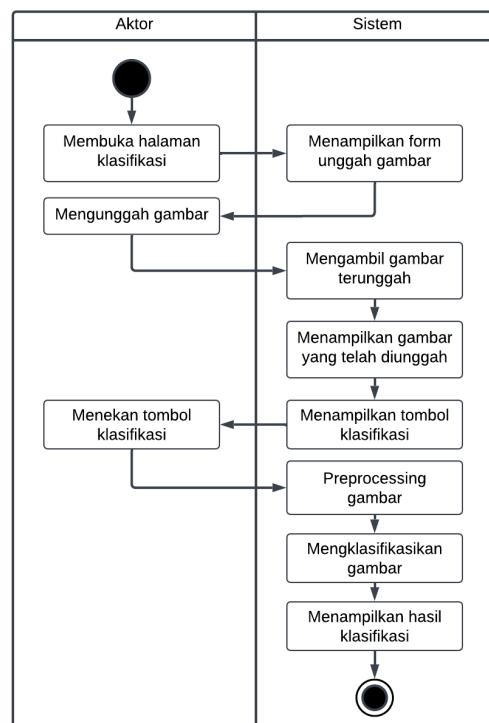


Gambar 26. *Use case diagram*.

Pada *use case diagram* yang dirancang, terdapat satu aktor utama, yaitu *User*. *User* memiliki tiga aktivitas utama, yaitu melihat panduan penggunaan sistem, mengunggah citra daun tumbuhan obat, dan melihat hasil klasifikasi. *Activity diagram* sistem dirancang dalam dua bagian terpisah: alur untuk melihat panduan penggunaan ditampilkan pada Gambar 27, sedangkan alur untuk mengunggah gambar dan menampilkan hasil klasifikasi dapat ditunjukkan pada Gambar 28.



Gambar 27. *Activity diagram* melihat panduan penggunaan.



Gambar 28. *Activity diagram* mengunggah dan melihat klasifikasi.

b. Implementasi Sistem

Sistem ini akan dibangun menggunakan bahasa pemrograman *python* dengan bantuan *library Streamlit* dan *TensorFlow*. *Library Streamlit* akan digunakan untuk membangun antarmuka pengguna, dan *library TensorFlow* akan digunakan untuk mengimplementasikan dan menjalankan model *machine learning* yang telah dibangun.

c. Pengujian Sistem

Sistem ini akan diuji menggunakan metode *black box testing* oleh 5 orang *software developer* berpengalaman. Skenario pengujian pada sistem ini disajikan pada Tabel 6.

Tabel 6. Skenario pengujian *black box testing*.

Kode Uji	Skenario	Input	Ekspektasi Output
A1	Mengunggah gambar dalam format yang valid (jpg, jpeg, png)	Unggah gambar .jpg, .jpeg, .png	Gambar tampil di UI, tombol klasifikasi muncul (jpg, jpeg, png)
A2	Mengunggah gambar rusak atau tidak terbaca	Unggah file gambar corrupt	Muncul pesan error
A3	Tombol klasifikasi muncul hanya jika ada gambar	Belum unggah gambar	Tombol klasifikasi muncul hanya muncul setelah gambar ada, Setelah berhasil diunggah
A4	Klasifikasi berhasil dilakukan	Klik tombol klasifikasi setelah unggah gambar	Muncul hasil klasifikasi dari dua model: nama kelas, conf, dan waktu eksekusi
A5	Ganti gambar setelah klasifikasi	Unggah gambar kedua	Gambar sebelumnya terganti, hasil prediksi sebelumnya tidak ditampilkan

V. SIMPULAN DAN SARAN

5.1. Simpulan

Simpulan dari penelitian yang telah dilakukan sebagai berikut:

- a. Arsitektur *EfficientNetV2B0* dan *Xception* berhasil dikembangkan dalam klasifikasi citra daun tumbuhan obat dengan pendekatan *transfer learning* menggunakan bobot *pre-trained ImageNet*.
- b. *EfficientNetV2B0* menunjukkan kinerja yang lebih unggul dibandingkan dengan *Xception*, baik dalam hal akurasi maupun waktu *training*. Rata-rata akurasi *EfficientNetV2B0* adalah 99.5% dengan waktu *training* rata-rata 159 detik, sedangkan *Xception* memiliki rata-rata akurasi 98.33% dan waktu *training* 291 detik.
- c. Penelitian ini juga telah berhasil membangun *website* yang dapat mengunggah citra daun tumbuhan obat dan memberikan hasil klasifikasi ilmiah secara otomatis, sehingga dapat menjadi alat bantu dalam mengklasifikasikan tumbuhan obat secara digital.

5.2. Saran

Saran yang dapat diberikan untuk melanjutkan penelitian ini sebagai berikut:

- a. Memperbaiki teknik pengambilan data secara langsung agar data yang diperoleh lebih akurat dan representatif.
- b. Menambahkan jumlah kelas agar model mampu mengklasifikasikan lebih banyak jenis tumbuhan obat.

- c. Menambahkan jumlah data pada setiap kelas agar model dapat mempelajari representasi fitur dengan lebih baik dan menghasilkan performa klasifikasi yang lebih optimal.
- d. Mengeksplorasi teknik penanganan *out of distribution* data agar model lebih tahan terhadap data non-kelas ataupun data yang tidak relevan.
- e. Menerapkan teknik augmentasi data untuk meningkatkan jumlah dan keragaman data, sehingga model dapat belajar dari variasi bentuk dan kondisi pencahayaan yang lebih beragam.
- f. Mengeksplorasi penggunaan berbagai arsitektur lainnya, seperti *YOLO*, *Transformer-based*, *Confnet*, *DenseNet* atau arsitektur lainnya untuk membandingkan hasil akurasi dengan arsitektur lainnya agar mendapatkan hasil yang optimal.

DAFTAR PUSTAKA

- Agarwal, R. (2019, Oktober 22). *How to Write Web Apps Using Simple Python for Data Scientists*. KDnuggets. Diakses pada tanggal 30 Januari 2025, dari <https://www.kdnuggets.com/2019/10/write-web-apps-using-simple-python-data-scientists.html>.
- Alghifari, F., & Juardi, D. (2021). Penerapan Data Mining Pada Penerapan Data Mining Pada Penjualan Makanan Dan Minuman Menggunakan Metode Algoritma Naïve Bayes. *Jurnal Ilmiah Informatika (JIF)*, 9(2).
- Ambarwati, D., Nugraheni, D. R., Fadiyah, I., & Ingawana, N. S. (2024). Identifikasi Tumbuhan Obat Yang Terdapat Di Kebun Raya Purwodadi Pasuruan. *Jurnal Konservasi Sumber Daya Alam dan Lingkungan (CONSERVA)*, 2(01), 32–48.
- Andini, D. (2023). Jaringan Syaraf Tiruan Untuk Klasifikasi Penyakit Demam Menggunakan Algoritma Backpropagation. *Bulletin of Artificial Intelligence*, 2(1), 86–99.
- Ardinimia, S. D., Putri, A. F., Putra, Y. M. R., Dzakiyyah, N. P. H., & Lombu'u, P. G. (2023). Review: Bioaktivitas Daun Bidara (Ziziphus mauritiana Lamk.). *Indonesian Chemistry and Application Journal*, 6(2), 9–18.
- 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), 2548–6861.
- Auliya, D., Saptadi, D., & Kuswanto, D. (2018). Eksplorasi Tanaman Kelor (*Moringa oleifera* Lam.) di Kabupaten Banyuwangi Jawa Timur. *Jurnal Produksi Tanaman*, 6(11), 2874–2882.
- Azmi, K., Defit, S., & Sumijan, S. (2023). Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat. *Jurnal Unitek*, 16(1), 28–40.
- Bame, H. (2020, Oktober 13). *Pulai Berkhasiat untuk Demam, Darah tinggi, dan Diabetes*. INAKORAN. Diakses pada tanggal 29 Januari 2025, dari <https://inakoran.com/pulai-berkhasiat-untuk-demam-darah-tinggi-dan-diabetes/p26994>.

- Bekkar, M., Djemaa, Dr. H. K., & Alitouche, Dr. T. A. (2013). Evaluation Measures for Models Assessment over Imbalanced Data Sets. *Journal of Information Engineering and Applications*, 3(10), 27–38.
- Bhelkar, N. S., & Sharma, A. (2022). Identification and classification of medicinal plants using leaf with deep convolutional neural networks. *International journal of health sciences*, 6(S6), 11596–11605.
- Carnagie, J. O., Prabowo, A. R., Budiana, E. P., & Singgih, I. K. (2022). Essential Oil Plants Image Classification Using Xception Model. *Procedia Computer Science*, 204, 395–402.
- Chollet, F. (2016, Oktober 7). Xception: Deep Learning with Depthwise Separable Convolutions. *Xception: Deep Learning with Depthwise Separable Convolutions. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Chougule, O., Katheria, D., Jain, K., & Shinde, S. (2022, Agustus 28). Tomato Blight Classification Using Transfer Learning and Fine Tuning. *2022 2nd Asian Conference on Innovation in Technology, ASIANCON 2022*.
- Dinas Pertanian Kabupaten Buleleng. (2019). *Manfaat Daun Sambung Nyawa Bagi Kesehatan*. DISTAN BULELENG BERITA. Diakses pada tanggal 12 Desember 2024, dari <https://distan.bulelengkab.go.id/informasi/detail/berita/manfaat-daun-sambung-nyawa-bagi-kesehatan-62>.
- Fajrina, A. N., Pradana, Z. H., Purnama, S. I., & Romadhona, S. (2024). Penerapan Arsitektur EfficientNet-B0 Pada Klasifikasi Leukimia Tipe Acute Lymphoblastik Leukimia. *Jurnal Riset Rekayasa Elektro*, 6(1), 59–68.
- Fathaddin, M. T., Safitri, U., Ridaliani, O., Widiyatni, H., Rakhamanto, P. A., Nuansa, Z., Antariksa, A., & Wijayanto, D. (2022). Evaluasi Penyuluhan Manfaat Cincau Bagi Kesehatan dan Kecantikan Pada Masyarakat Kelurahan Curug Kotamadya Bogor. *Jurnal Akal: Abdimas dan Kearifan Lokal*, 3, 224–2302.
- Firmansyah, I., & Hayadi, B. H. (2022). Komparasi Fungsi Aktivasi ReLU dan TanH pada Multilayer Perceptron. *JIKO (Jurnal Informatika dan Komputer)*, 6(2), 200–206.
- Haba, F. S., Purnama, M. M. E., & Mau, A. E. (2022). Diversity Of Types And Utilization of Medicine Plants in the Forest Bu'at So'es Research Forest, South Mollo District, Timor Regency South Central, East Nusa Tenggara Province. *Jurnal Wana Lestari*, 04(1), 182–193.

- 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.
- Irsyad, A., Islamiyah, I., & Amal, F. (2023). Klasifikasi COVID 19 dengan Metode EfficientNet Berdasarkan CT Scan Paru-Paru. *Fountain of Informatics Journal*, 8(2), 2548–5113.
- Jeon, W. S., & Rhee, S. Y. (2017). Plant leaf recognition using a convolution neural network. *International Journal of Fuzzy Logic and Intelligent Systems*, 17(1), 26–34.
- Kementrian Kesehatan Republik Indonesia. (2015). *100 Top Tanaman Obat Indonesia* (2 ed.). Kementrian Kesehatan RI - Balai Besar Litbang Tanaman Obat dan Obat Tradisional.
- Kementrian Kesehatan Republik Indonesia. (2017). *Keputusan Menteri Kesehatan Republik Indonesia NOMOR HK.01.07/MENKES/187/2017 tentang Formularium Ramuan Obat Tradisional Indonesia*.
- Kidarsa, B. (2014). Binahong, Herbal Berkhasiat Obat. *Ebers Papyrus*, 20(1), 5–8.
- Kiranti, D. (2023, Maret 11). *Apa itu Dataset?* Medium. Diakses pada tanggal 29 Januari 2025, dari <https://medium.com/@dilakiranti27/apa-itu-dataset>.
- Kundu, R. (2022, September 13). *Confusion Matrix: How To Use It & Interpret Results [Examples]*. V7. Diakses pada tanggal 06 Juli 2025, dari <https://www.v7labs.com/blog/confusion-matrix-guide>.
- Lathifah, K. (2024). *Manfaat Daun Cincau Hijau untuk Kesehatan*. Radio Republik Indonesia. Diakses pada tanggal 12 Desember 2024, dari <https://rri.co.id/lainlain/831808/manfaat-daun-cincau-hijau-untuk-kesehatan>.
- Latifa, R. (2020). Karakter Morfologi Daun Beberapa Jenis Pohon Penghijauan Hutan Kota di Kota Malang. *Jurnal Bionatural Pendidikan*, 3(1), 667–676.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Lestari, H. C. (2023). *Klasifikasi Citra Daun Tumbuhan Obat Menggunakan Deteksi Tepi Canny Dan Metode K-Nearest Neighbor (KNN)*. Universitas Lampung.
- Manoi, F. (2019). Binahong Anrederacordifolia (Tenore Steen) sebagai Obat. *Jurnal Warta Penelitian Dan Pengembangan Tanaman Industri*, 15.
- Marco, A. (2024, April 23). *Streamlit dan Python*. Medium. Diakses pada tanggal 30 Januari 2025, dari <https://medium.com/@alvinmarco8/streamlit-dan-python-ce9a11eaa6a8>.

- Mardiana, B. D., Budi Utomo, W., Nur Oktaviana, U., Wasis Wicaksono, G., & Eko Minarno, A. (2023). Herbal Leaves Classification Based on Leaf Image Using CNN Architecture Model VGG16. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 7(1), 20–26.
- Maxwell, A. E., Warner, T. A., & Guillén, L. A. (2021). Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies—Part 1: Literature Review. *Remote Sensing*, 13(13).
- Mayarlis, M., & Chatri, M. (2024). Potensi Ketapang (*Terminalia catappa* L.) sebagai Tanaman Obat. *Jurnal Pendidikan Tambusai*, 8(2), 18504–18509.
- Mayor, J. M. K., & Wattimena, L. (2022). Pemanfaatan Pohon Pulai (*Alstonia Scholaris*) oleh Masyarakat Kampung Puper Distrik Waigeo Timur Kabupaten Raja Ampat. *Jurnal J-Mace*, 2(1), 68–81.
- Moeljanto, R. D., & Mulyono, M. (2003). *Khasiat & Manfaat Daun Sirih Obat Mujarab dari Masa ke Masa* (T. Tetty, Ed.; 1 ed.). PT AgroMedia Pustaka.
- Muhammad, S., & Wibowo, A. T. (2021). Klasifikasi Tanaman Aglaonema Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network (CNN). *e-Proceeding of Engineering*, 10621–11063.
- Mujahid, P. E., Manik, R., Simbolon, J. S., Ratna, M. R., Sinaga, S., Aisyah, S., & Nababan, M. (2024). Herbal Leaf Image Classification Using Convolutional Neural Network (CNN). *Jurnal Sistem Informasi dan Ilmu Komputer Prima*, 8(1).
- Ningrum, L. W. (2021). Sebaran Jenis Tanaman *Terminalia catappa* L. Beserta Potensi Benihnya di Kebun Raya Purwodadi. *Prosiding Biologi Achieving the Sustainable Development Goals with Biodiversity in Confronting Climate Change*, 196–203.
- Novalina, N., & Rizkinia, M. (2023). Implementation of Xception and EfficientNetB3 for COVID-19 Detection on Chest X-Ray Image via Transfer Learning. *International Journal of Electrical, Computer, and Biomedical Engineering*, 1(2), 168–178.
- Nurdiana, N. (2020). *Morfologi Tumbuhan* (E. M. Jayadi, Ed.; 1 ed.). Sanabil.
- Nurfauzi, A. H., Azhar, Y., & Chandranegara, D. R. (2023). Penerapan Model EfficientNetV2-B0 pada Benchmark IP102 Dataset untuk Menyelesaikan Masalah Klasifikasi Hama Serangga. *REPOSITOR*, 5(3), 805–814.
- Nusantoro, J., Afrinanto, F. F., Labibah, W. S., Sari, Z., & Azhar, Y. (2022). Detection of Covid-19 on X-Ray Image of Human Chest Using CNN and Transfer Learning. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(3), 430–441.

- Perpustakaan Kementerian Pekerjaan Umum. (2025). *Pulai*. Perpustakaan Kementerian Pekerjaan Umum. Diakses pada tanggal 12 Desember 2024, dari <https://pu.go.id/pustaka/dokumentasi/pulai/876E9>.
- Peryanto, A., Yudhana, A., & Umar, D. R. (2019). Rancang Bangun Klasifikasi Citra Dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network. *Jurnal Format*, 8(2), 2089–5615.
- Pratama, S. D., Lasimin, L., & Dadaprawira, M. N. (2023). Pengujian Black Box Testing Pada Aplikasi Edu Digital Berbasis Website Menggunakan Metode Equivalence Dan Boundary Value. *Jurnal Teknologi Sistem Informasi dan Sistem Komputer TGD*, 6(2), 560–569.
- Pujiati, R., & Rochmawati, N. (2022). Identifikasi Citra Daun Tanaman Herbal Menggunakan Metode Convolutional Neural Network (CNN). *Journal of Informatics and Computer Science*, 03.
- Purwitasari, N. A., & Soleh, M. (2022). Implementasi Algoritma Artificial Neural Network Dalam Pembuatan Chatbot Menggunakan Pendekatan Natural Language Processing. *Jurnal IPTEK*, 6(1), 14–21.
- 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.
- Qonitah, F., & Ahwan, A. (2018). Aktivitas Antioksidan dan Kandungan Fenolik Total dari Isolat Polar Fraksi Heksana Ekstrak Etanol Daun Sirih (Piper Betle L.). *Jurnal Farmasetis*, 7(1), 42–46.
- Rachman, A. F., Ridwan, D. A., Kartono, K., Damarudin, S., & Saifudin, A. (2023). Kecerdasan Buatan Dalam Otomatisasi Pengujian Perangkat Lunak E-Commerce. *OKTAL: Jurnal Ilmu Komputer dan Science* , 2(6), 1742–1746.
- Raharjeng, S. W., & Masliyah, A. (2020). Identifikasi Morfologi Bidara (Ziziphus mauritiana). *Jurnal Farmasi Indonesia*, 1(2), 79–88.
- Rahayu, S., & Hasibuan, R. (2023). Pemanfaatan Tanaman Kelor (Moringa oleifera) sebagai Obat Tradisional di Dusun Aek Kulim Mandasena Kabupaten Labuhanbatu Selatan. *Bioscientist : Jurnal Ilmiah Biologi*, 11(1), 386.
- Rai, I. G. A., Suryatini, K. Y., Wistari, N. M., & Subrata, I. M. (2023). Biodiversitas Tumbuhan Obat di Desa Kedisan Kecamatan Tegallalang Kabupaten Gianyar. *Emasains : Jurnal Edukasi Matematika dan Sains*, 12(2), 88–95.
- 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*.

- Rangkuti, M. (2024). *15 Manfaat Daun Ketapang*. UMSU Artikel. Diakses pada tanggal 12 Desember 2024, dari <https://umsu.ac.id/artikel/15-manfaat-daun-ketapang>.
- Sadiyah, H. H., Cahyadi, A. I., & Windria, S. (2022). Kajian Daun Sirih Hijau (Piper betle L) Sebagai Antibakteri. *Jurnal Sain Veteriner*, 40(2), 128.
- Salim, Z., & Munadi, E. (2017). *Info Komiditi Tanaman Obat*. Jakarta: Badan Pengkajian dan Pengembangan Perdagangan.
- Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *BM J. Res. Dev*, 3(3), 210–229.
- Sarno, S. (2019). Pemanfaatan Tanaman Obat (Biofarmaka) Sebagai Produk Unggulan Masyarakat Desa Depok Banjarnegara. *Abdimas Unwahas*, 4(2), 73–78.
- Setyawan, W. D., Nilogiri, A., & A'yun, Q. (2023). Implementasi Convolution Neural Network (CNN) untuk Klasifikasi pada Citra Ikan Cupang Hias. *Jurnal Teknik Informatika Kaputama (JTIK)*, 7(1), 101–110.
- Silalahi, M. (2020). Pemanfaatan Kecibeling (Strobilanthes crispia) Sebagai Obat Tradisional dan Bioaktivitasnya. *Jurnal Emasains: Jurnal Edukasi Matematika dan Sains*, 9(2), 196–205.
- Suhendra, C. D., & Saputra, A. C. (2020). Penentuan Parameter Learning Rate Selama Pembelajaran Jaringan Syaraf Tiruan Backpropagation Menggunakan Algoritma Genetika. *Jurnal Teknologi Informasi: Jurnal Keilmuan dan Aplikasi Bidang Teknik Informatika*, 14(2), 202–212.
- Suprapto, H. (2020). *10 Manfaat Daun Salam yang Wajib Kamu Tahu, untuk Pria dan Wanita*. Hops.ID. Diakses pada tanggal 11 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. (2019). Enhanced deep convolutional neural network for malarial parasite classification. *International Journal of Computers and Applications*, 44(12), 1113–1122.
- 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.
- Susanti, A., & Nurman, M. (2022). Manfaat Kelor (Moringa Oleifera) Bagi Kesehatan. *Jurnal Kesehatan Tambusai*, 3(3), 509–513.
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *Proceedings of the 36th International Conference on Machine Learning*, 6105–6114.

- Tan, M., & Le, Q. V. (2021, April 1). EfficientNetV2: Smaller Models and Faster Training. *International Conference on Machine Learning*.
- Taupik, J., Alamsyah, T., & Wulandari, A. (2021). Rancang Bangun Foreign Object Debris (FOD) Detector pada Landasan Pacu dengan Arsitektur Deep Learning Berbasis Jaringan Mikrotik dan LabView. *Seminar Nasional Terapan Riset Inovatif (SENTRINOV) Ke-7 ISAS Publishing*.
- Utomo, D. S., Kristiani, E. B. E., & Mahardika, A. (2020). The Effect of Growth Location on Flavonoid, Phenolic, Chlorophyll, Carotenoid and Antioxidant Activity Levels in Horse Whip (Stachytarpheta Jamaicensis). *Jurnal Berkala Ilmiah Biologi*, 22(2), 143–149.
- Wibawa, M. S. (2016). Pengaruh Fungsi Aktivasi, Optimisasi dan Jumlah Epoch Terhadap Performa Jaringan Saraf Tiruan. *Jurnal Sistem dan Informatika*, 11(1), 1–8.
- 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).
- Wijaya, Y. D., & Astuti, M. W. (2021). Pengujian Blackbox Sistem Informasi Penilaian Kinerja Karyawan PT INKA (Persero) Berbasis Equivalence Partitions. *Jurnal Digital Teknologi Informasi*, 4(1), 22–26.
- Yogasuria, E. (2011). *Renyahnya Keripik Sirih*. BBPP LEMBANG. Diakses pada tanggal 11 Desember 2024, dari <https://bbpplembang.bppsdmp.pertanian.go.id/publikasi-detail/1136>.
- Zafar, A., Aamir, M., Mohd Nawi, N., Arshad, A., Riaz, S., Alruba, A., Dutta, A. K., & Almotairi, S. (2022). A Comparison of Pooling Methods for Convolutional Neural Networks. *Applied Sciences*, 12(17).