

**KLASIFIKASI DAUN HERBAL BERBASIS CITRA MENGGUNAKAN
CONVOLUTIONAL NEURAL NETWORK (CNN) DENGAN
HYPERPARAMETER TUNING RANDOM SEARCH**

SKRIPSI

DISUSUN OLEH

ICHSAN ARIF

2109020124



UMSU

Unggul | Cerdas | Terpercaya

**PROGRAM STUDI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**

MEDAN

2025

**KLASIFIKASI DAUN HERBAL BERBASIS CITRA MENGGUNAKAN
CONVOLUTIONAL NEURAL NETWORK (CNN) DENGAN
HYPERPARAMETER TUNING RANDOM SEARCH**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer
(S.Kom) dalam Program Studi Teknologi Informasi pada Fakultas Ilmu Komputer
dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara**

ICHSAN ARIF

2109020124

**PROGRAM STUDI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**

MEDAN

2025

LEMBAR PENGESAHAN

Judul Skripsi : KLASIFIKASI DAUN HERBAL BERBASIS CITRA
MENGUNAKAN CONVOLUTIONAL NEURAL
NETWORK (CNN) DENGAN HYPERPARAMETER
TUNING RANDOM SEARCH

Nama Mahasiswa : Ichsan Arif
NPM : 2109020124
Program Studi : Teknologi Informasi

Menyetujui
Komisi Pembimbing



(Mahardika Abdi Prawira S.Kom, M.Kom)
NIDN. 0117088902

Ketua Program Studi



(Fatma Sari Hutagalung S.Kom, M.Kom)
NIDN. 0117019301

Dekan



(Dr. Al-Khowarizmi, S.Kom., M.Kom.)
NIDN. 0127099201

PERNYATAAN ORISINALITAS

KLASIFIKASI DAUN HERBAL BERBASIS CITRA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) DENGAN HYPERPARAMETER TUNING RANDOM SEARCH

SKRIPSI

Saya menyatakan bahwa karya tulis ini adalah hasil karya sendiri, kecuali beberapa kutipan dan ringkasan yang masing-masing disebutkan sumbernya.

Medan, 21 Agustus 2025

Yang membuat pernyataan



Ichsan Agha

NPM.2100920124

**PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN
AKADEMIS**

Sebagai sivitas akademika Universitas Muhammadiyah Sumatera Utara, saya bertanda tangan dibawah ini:

Nama	: Ichsan Arif
NPM	: 2109020124
Program Studi	: Teknologi Informasi
Karya Ilmiah	: Skripsi


Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Muhammadiyah Sumatera Utara Hak Bedas Royalti Non-Eksekutif (*Non-Exclusive Royalty free Right*) atas penelitian skripsi saya yang berjudul:
“Klasifikasi Daun Herbal Berbasis Citra Menggunakan Convolutional Neural Network (CNN) Dengan Hyperparameter Tuning Random Search”

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Non-Eksekutif ini, Universitas Muhammadiyah Sumatera Utara berhak menyimpan, mengalih media, memformat, mengelola dalam bentuk database, merawat dan mempublikasikan Skripsi saya ini tanpa meminta izin dari saya selama tetap mencantumkan nama saya sebagai penulis dan sebagai pemegang dan atau sebagai pemilik hak cipta.

Demikian pernyataan ini dibuat dengan sebenarnya.

Medan, 21 Agustus 2025

Yang membuat pernyataan



Ichsan Arif

NPM. 2109020124

RIWAYAT HIDUP

DATA PRIBADI

Nama Lengkap : Ichsan Arif
Tempat dan Tanggal Lahir : Medan, 24 September 2003
Alamat Rumah : Jl.Pengilar Gg.Pengilar baru No 56D
Telepon/Faks/HP : 082366755433
E-mail : ichsanarif2409@gmail.com
Instansi Tempat Kerja : -
Alamat Kantor : -

DATA PENDIDIKAN

SD	: SDN 064972 MEDAN	TAMAT: 2015
SMP	: SMPN 23 MEDAN	TAMAT: 2018
SMA	: SMAN 21 MEDAN	TAMAT: 2021

KATA PENGANTAR



Pendahuluan

Penulis tentunya berterima kasih kepada berbagai pihak dalam dukungan serta doa dalam penyelesaian skripsi. Penulis juga mengucapkan terima kasih kepada:

1. Bapak Prof. Dr. Agussani, M.AP., Rektor Universitas Muhammadiyah Sumatera Utara (UMSU)
2. Bapak Dr. Al-Khowarizmi, S.Kom., M.Kom. Dekan Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
3. Ibu Fatma Sari Hutagalung, S.Kom., M.Kom Ketua Program Studi Teknologi Informasi.
4. Bapak Mhd.Basri, S.Si., M.Kom Sekretaris Program Studi Teknologi Informasi.
5. Bapak Mahardika Abdi Prawira, S.Kom., M.Kom selaku dosen pembimbing saya yang membantu membimbing dan memberikan saran kepada penulis dalam penyusunan skripsi ini.
6. Orang tua saya, Ibu saya yang bernama Supiatun seseorang yang tidak pernah lelah dalam memberikan semangat dan doa yang tidak terputus putus kepada saya yang menjadikan motivasi saya dalam penyusunan skripsi ini.
7. Teruntuk sosok yang tidak pernah hadir secara fisik, namun selalu hidup dalam doa dan semangat saya, ayah saya Alm. Al Ishak. Tidak ada pelukan yang bisa saya balas, tidak ada kabar bahagia ini yang bisa saya sampaikan secara langsung. Tapi izinkan saya mempersembahkan karya ini sebagai bukti bahwa anakmu tetap berjalan, walau tertatih tanpa kehadiranmu.
8. Orang terdekat saya mbak saya mbak imah,mbak dhila,mbak Ajeng yang selalu menyemangati saya adiknya dalam penyusunan skripsi ini serta keponaan saya Shakira,Kesya,Mayra,Zea penyemangat saya disaat saya lelah.

9. Teman teman terdekat saya Muhazrin Ibnu,Fahriza Sinuraya,Rizki Adhar,Sabaruddin Akbar,Fachrurozi Suwardi,Naufal Fauzi Lubis,Alfian Helmi yang telah memberikan bantuan,semangat dan dukungan kepada penulis.
10. Teman teman kelas C1 Pagi Teknologi Informasi yang selalu memberikan semangat dan dukungan kepada penulis.
11. Kepada seseorang yang pernah bersama penulis dan tidak bisa penulis sebut namanya. Terimakasih untuk rasa patah hati yang diberikan saat proses penyusunan skripsi yang sekarang bisa menjadi pengingat untuk saya sehingga dapat membuktikan bahwa anda akan tetap menjadi alasan saya untuk berproses menjadi pribadi yang lebih baik. Terimakasih telah menjadi bagian yang menyenangkan dan menyakitkan dalam proses pendewasaan penulis.
12. Dan yang terakhir kepada diriku sendiri, terimakasih telah bertahan Terima kasih karena tidak menyerah saat dunia seolah ikut menekan. Terima kasih karena telah menolak untuk berhenti, meski rasa lelah sering mengaburkan arah. Dalam perjalanan panjang menyusun skripsi ini, aku telah menyaksikan bagaimana diriku tumbuh pelan, tapi pasti. Aku bangga, bukan karena hasil yang sempurna, tapi karena proses penuh luka, doa, dan tekad yang tak goyah. Terima kasih telah terus melangkah, meski berkali-kali ingin menyerah. Terima kasih telah memilih jalan yang sulit, bukan jalan yang singkat.

KLASIFIKASI DAUN HERBAL BERBASIS CITRA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) DENGAN HYPERPARAMETER TUNING RANDOM SEARCH

ABSTRAK

Pemanfaatan teknologi seperti *computer vision*, *machine learning*, dan *deep learning* memungkinkan otomatisasi dalam pengolahan data visual, menggantikan metode manual yang lambat dan rentan kesalahan. Salah satu penerapan potensial adalah klasifikasi citra daun herbal menggunakan algoritma *deep learning*. Model *Convolutional Neural Network* (CNN) terbukti efektif dalam mengekstraksi fitur visual dari gambar daun dan menghasilkan klasifikasi yang akurat. Namun, performa CNN sangat bergantung pada konfigurasi parameter internal atau *hyperparameter*. Tanpa penyetelan (*tuning*) yang tepat, akurasi model bisa menurun drastis. Untuk mengatasi hal ini, penelitian ini menerapkan teknik *hyperparameter tuning* dengan metode *Random Search*, yang mengeksplorasi kombinasi nilai seperti jumlah filter, ukuran kernel, *learning rate*, *batch size*, dan jumlah *epoch*. Teknik ini meningkatkan performa CNN secara signifikan. Penelitian ini mengklasifikasikan tiga jenis daun herbal: daun sirih, daun kemangi, dan daun jambu biji. Hasilnya, sistem berhasil memprediksi gambar daun baru dengan tingkat akurasi dan kepercayaan tinggi. CNN yang telah di-*tuning* mampu mengenali pola visual penting seperti tekstur, tepi, dan bentuk dengan lebih baik. Dengan bantuan pemrograman Python, sistem klasifikasi daun herbal ini dapat dikembangkan secara efektif dan dapat membantu masyarakat mengenali jenis daun herbal secara otomatis dan efisien.

Kata Kunci: Convolutional Neural Network (CNN), Daun Herbal, Hyperparameter Tuning, Random Search

IMAGE-BASED HERBAL LEAF CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORKS (CNN) WITH HYPERPARAMETER TUNING RANDOM SEARCH

ABSTRACT

The use of technologies such as computer vision, machine learning, and deep learning enables automation in visual data processing, replacing slow and error-prone manual methods. One potential application is the classification of herbal leaf images using deep learning algorithms. Convolutional Neural Network (CNN) models have proven effective in extracting visual features from leaf images and producing accurate classifications. However, CNN performance is highly dependent on the configuration of internal parameters, or hyperparameters. Without proper tuning, model accuracy can decrease drastically. To address this, this study applied a hyperparameter tuning technique using the Random Search method, which explores combinations of values such as the number of filters, kernel size, learning rate, batch size, and number of epochs. This technique significantly improved CNN performance. This study classified three types of herbal leaves: betel leaves, basil leaves, and guava leaves. The system successfully predicted new leaf images with high accuracy and confidence. The tuned CNN was able to better recognize important visual patterns such as texture, edges, and shape. With the help of Python programming, this herbal leaf classification system can be developed effectively and can help people recognize the types of herbal leaves automatically and efficiently.

Keywords: Convolutional Neural Network (CNN), Herbal Leaves, Hyperparameter Tuning, Random Search

DAFTAR ISI

LEMBAR PENGESAHAN	i
PENYATAAN ORISINALITAS	ii
PENYATAAN PERSETUJUAN PUBLIKASI	iii
RIWAYAT HIDUP	iv
KATA PENGANTAR.....	v
ABSTRAK	vii
ABSTRACT	viii
DAFTAR ISI.....	ix
DAFTAR TABEL	xi
DAFTAR GAMBAR.....	xii
BAB I. PENDAHULUAN	1
1.1. LATAR BELAKANG MASALAH.....	1
1.2. RUMUSAN MASALAH	4
1.3. BATASAN MASALAH	4
1.4. TUJUAN PENELITIAN	5
1.5. MANFAAT PENELITIAN.....	6
BAB II. LANDASAN TEORI	7
2.1. Penelitian Terdahulu.....	7
2.2. Daun Herbal	9
2.3. Klasifikasi.....	12
2.4. Citra Digital.....	13
2.4.1 Citra RGB dan Grayscale	14

2.4.2 Proses Pengolahan Citra	15
2.5. Convolutional Neural Network (CNN)	16
2.6. Hyperparameter Tuning	22
2.7. Random Search.....	23
2.8. Tolls Pendukung.....	24
2.8.1 Python.....	23
BAB III. METODOLOGI PENELITIAN	27
3.1. Metode Penelitian.....	27
3.2. Instrumen Penelitian.....	28
3.3. Alur Penelitian.....	29
3.4. Arsitektur CNN	32
3.5. Perancangan model	34
BAB IV. HASIL DAN PEMBAHASAN	37
4.1. Tujuan Program.....	37
4.2. Parameter Acak	38
4.3. Contoh Proses.....	40
4.4. Evaluasi Akhir.....	42
4.5. Prediksi Gambar Baru	43
BAB V. KESIMPULAN DAN SARAN	57
5.1. KESIMPULAN	57
5.2. SARAN	57
DAFTAR PUSTAKA.....	59
LAMPIRAN.....	64

DAFTAR TABEL

Tabel 2.1 Penelitian Terdahulu	7
Tabel 3.1 Instrumen Penelitian	28
Tabel 4.1 Pseudocode Pembacaan Folder	37
Tabel 4.2 Parameter Acak	38
Tabel 4.3 Pseudocode Parameter Acak	38
Tabel 4.4 Pseudocode Model CNN	40
Tabel 4.5 Model Dilatih	41
Tabel 4.6 Pseudocode Nilai akurasi	41
Tabel 4.7 Perbandingan Iterasi	42
Tabel 4.8 Pseudocode Perbandingan Iterasi	42
Tabel 4.9 Pseudocode Evaluasi Akhir	43
Tabel 4.10 Hasil Prediksi	45

DAFTAR GAMBAR

Gambar 2.1 Daun Kemangi	9
Gambar 2.2 Daun Jambu Biji.....	10
Gambar 2.3 Daun Sirih	11
Gambar 2.4 Arsitektur CNN	17
Gambar 2.5 Ilustrasi Proses Average Pooling.....	20
Gambar 2.6 Ilustrasi Proses Fully Connected Layer.....	21
Gambar 3.1 Alur Penelitian	29
Gambar 3.2 Arsitektur CNN	32
Gambar 3.3 Perancangan Model	34
Gambar 4.1 Folder Dataset	37
Gambar 4.2 Grafik Hasil Uji Daun Herbal	55

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Perkembangan teknologi digital dan kecerdasan buatan saat ini telah memasuki berbagai ranah kehidupan, termasuk bidang pertanian dan pengolahan tanaman obat. Pemanfaatan teknologi seperti *computer vision*, *machine learning*, dan *deep learning* memungkinkan sistem untuk melakukan tugas-tugas klasifikasi, identifikasi, bahkan diagnosis, yang memungkinkan otomatisasi proses pengolahan data visual secara efisien dan objektif, menggantikan metode manual yang memerlukan waktu dan rentan kesalahan (Joshi et al., 2024). Salah satu penerapan menarik dari perkembangan ini adalah pengenalan dan klasifikasi tanaman herbal berbasis citra daun.

Tanaman herbal memegang peranan penting dalam pengobatan tradisional di berbagai belahan dunia. Namun, identifikasi tanaman herbal secara konvensional masih banyak mengandalkan pengamatan visual dan pengetahuan lokal yang bersifat subjektif. Kondisi ini sering kali menimbulkan ketidaktepatan dalam pengenalan jenis tanaman, khususnya ketika dihadapkan pada bentuk daun yang mirip secara morfologi maupun warna. Kesalahan identifikasi dapat berdampak pada penggunaan tanaman yang tidak tepat dalam pengobatan tradisional. Oleh karena itu, integrasi teknologi berbasis kecerdasan buatan (AI) dan pembelajaran mesin (ML) dalam sistem klasifikasi tanaman herbal telah menjadi krusial untuk meningkatkan akurasi dan efisiensi proses identifikasi tanaman secara otomatis (Pushpa et al., 2024).

Salah satu solusi yang potensial untuk masalah ini adalah penggunaan metode klasifikasi berbasis citra daun dengan memanfaatkan algoritma *deep learning*. Model seperti *Convolutional Neural Network* (CNN) telah terbukti efektif dalam melakukan ekstraksi fitur visual dari gambar daun dan menghasilkan klasifikasi yang akurat. Dalam penelitian oleh (Azizah et al., 2024), algoritma *deep learning* mampu mencapai akurasi hingga 84% dalam mengenali jenis daun tanaman herbal dari 1650 citra menggunakan pendekatan *supervised learning*.

Meskipun demikian, akurasi model *deep learning* sangat bergantung pada kualitas konfigurasi parameter internal model atau yang dikenal sebagai *hyperparameter tuning*. Tanpa pengaturan *hyperparameter* yang tepat, performa model cenderung fluktuatif, bahkan gagal dalam melakukan klasifikasi yang benar. Seperti dijelaskan oleh (Fahmi et al., 2025), proses *hyperparameter tuning* memberikan dampak signifikan terhadap akurasi model *LightGBM* dalam mengklasifikasi rempah rimpang berbasis warna citra daun.

Dalam proses *hyperparameter tuning*, terdapat beberapa pendekatan yang dapat digunakan untuk meningkatkan performa model klasifikasi, seperti *grid search* dan *random search*. Metode ini bekerja dengan mengevaluasi berbagai kombinasi parameter untuk menemukan konfigurasi terbaik berdasarkan hasil uji model. Menurut penelitian oleh (Tanjung et al., 2021) *hyperparameter tuning* secara signifikan mampu meningkatkan akurasi model klasifikasi, penelitian ini menggunakan algoritma *Random Forest* yang menunjukkan peningkatan akurasi hingga +1.74% setelah dilakukan penyesuaian parameter. Proses tuning dilakukan dengan membandingkan berbagai kombinasi nilai *hyperparameter* secara eksperimen, sehingga hasil terbaik diperoleh dari konfigurasi yang di uji cobakan.

Penelitian ini juga menunjukkan bahwa proses tuning dapat berjalan dalam waktu singkat, yaitu sekitar 5-7 menit per algoritma, menjadikannya efisien untuk aplikasi praktis.

Dalam konteks konfigurasi *hyperparameter*, berbagai strategi seperti *grid search*, *random search*, dan *Bayesian optimization* digunakan untuk memperoleh konfigurasi model terbaik. Studi oleh (Elnursa et al., 2023) menunjukkan bahwa proses tuning pada parameter CNN, seperti jumlah *epoch*, *learning rate*, dan *batch size*, mampu meningkatkan akurasi klasifikasi citra simplisia herbal tradisional Madura secara signifikan. Penelitian tersebut menegaskan bahwa performa model sangat dipengaruhi oleh pemilihan *hyperparameter* yang tepat, terutama dalam sistem klasifikasi berbasis *transfer learning* dan CNN.

Selain pengaruh *hyperparameter*, pemilihan arsitektur CNN yang efisien juga menjadi faktor penting dalam klasifikasi citra daun herbal. Dalam studi oleh (Prilianti et al., 2024), penggunaan arsitektur MobileNetV2 dengan *fine tuning* terbukti memberikan akurasi tinggi dalam klasifikasi citra tanaman hias. Meskipun bukan tanaman herbal, prinsip dasar pengolahan citra dan tuning parameter model memiliki kesamaan, terutama dalam hal pemrosesan fitur tekstur dan morfologi daun.

Berdasarkan paparan di atas, penelitian ini bertujuan untuk mengembangkan model klasifikasi daun herbal berbasis citra dengan pendekatan *hyperparameter tuning* yang optimal. Fokus utama terletak pada bagaimana pemilihan dan konfigurasi parameter seperti jumlah *layer*, *learning rate*, *batch size*, dan *epoch* dengan menggunakan metode *Random Search* akan memengaruhi performa model CNN yang dikembangkan. Diharapkan model yang dihasilkan mampu membantu

masyarakat, peneliti, maupun industri herbal dalam melakukan klasifikasi tanaman secara otomatis, akurat, dan efisien.

Dengan adanya penelitian ini, diharapkan tercipta sistem klasifikasi daun herbal yang tidak hanya akurat namun juga efisien dan mudah diimplementasikan dalam skala luas. Selain itu, penelitian ini juga akan memberikan kontribusi pada pengembangan sistem berbasis AI untuk keperluan bioinformatika, konservasi tanaman, serta digitalisasi data tanaman herbal lokal Indonesia. Oleh karena itu, penelitian ini memiliki nilai strategis baik dari sisi teknologi maupun kebermanfaatan sosial.

1.2. Rumusan Masalah

Berdasarkan penjelasan pada latar belakang, maka rumusan masalah yang akan jadi fokus pada penelitian ini :

1. Bagaimana membangun model klasifikasi daun herbal berbasis citra menggunakan algoritma *Convolutional Neural Network* (CNN)?
2. Bagaimana pengaruh konfigurasi hyperparameter terhadap performa CNN dalam klasifikasi citra daun herbal?
3. Sejauh mana metode *Random Search* dapat mengoptimalkan performa model CNN dalam klasifikasi citra daun herbal?

1.3. Batasan Masalah

Adapun Batasan masalah dalam penelitian ini adalah sebagai berikut :

1. Penelitian ini hanya akan menggunakan citra daun dari spesies tanaman herbal tertentu yang telah dipilih dan dikumpulkan seperti :

- a. Daun kemangi (*Ocimum basilicum*)
 - b. Daun jambu biji (*Psidium guajava*)
 - c. Daun sirih (*piper betle L*)
2. Model yang digunakan adalah *Convolutional Neural Network* (CNN) tanpa membandingkan dengan arsitektur lain seperti *ResNet*, *EfficientNet*, atau *MobileNet*.
3. Penelitian hanya berfokus pada klasifikasi jenis daun herbal, bukan pengenalan bagian tanaman lain seperti akar atau batang.
4. Konfigurasi *hyperparameter* hanya dilakukan dengan metode *Random Search*, tanpa membahas metode tuning lainnya seperti *Grid Search* atau *Bayesian Optimization*.

1.4. Tujuan Penelitian

Adapun tujuan penelitian sebagai berikut :

1. Membangun sistem klasifikasi daun tanaman herbal berbasis citra digital menggunakan model CNN.
2. Menerapkan metode Random Search dalam proses *hyperparameter tuning* untuk menemukan kombinasi parameter optimal yang memberikan kinerja klasifikasi terbaik.
3. Mengembangkan sistem klasifikasi daun herbal yang bisa digunakan langsung di dunia nyata, baik oleh peneliti, industri herbal, maupun Masyarakat umum. Sistem ini dirancang agar mudah digunakan dan menghasilkan hasil yang akurat.

1.5. Manfaat Penelitian

Adapun manfaat penelitian sebagai berikut :

1. Memberikan kontribusi ilmiah dalam bidang pengolahan citra dan pembelajaran mesin, khususnya dalam penerapan CNN dan teknik hyperparameter tuning untuk klasifikasi objek biologis.
2. Memberikan solusi berbasis teknologi dalam identifikasi daun tanaman herbal yang sebelumnya hanya dilakukan secara manual.
3. Membantu industri herbal dan pengobatan tradisional dalam proses identifikasi tanaman secara efisien dan akurat.

BAB II

LANDASAN TEORI

2.1. Penelitian Terdahulu

Dalam penyusunan skripsi ini ada beberapa penelitian sebelumnya yang berkaitan dengan penulisan skripsi ini yang disajikan dalam bentuk Tabel 2.1

No	Penulis	Judul	Tahun	Kesimpulan
1	Nur Azizah et al.	Algoritma Deep Learning untuk Pengenalan Gambar Jenis Daun	2024	Penelitian menggunakan CNN, data augmentation, dan transfer learning pada 33 kelas daun. CNN menghasilkan akurasi tertinggi 94% saat validasi dan 84% saat pengujian. Teknik kombinasi ini menunjukkan hasil yang jauh lebih baik dibanding hanya CNN biasa.
2	Edwin Ariesto et al.	Teachable Machine: Optimization of Herbal Plant Image Classification Based on Epoch Value, Batch Size and Learning Rate	2024	Penelitian ini menunjukkan bahwa nilai epoch optimal untuk klasifikasi gambar daun herbal adalah 50 dengan learning rate 0.00001 dan ukuran batch 32, menghasilkan akurasi antara 98% hingga 100%. Meskipun peningkatan epoch dapat meningkatkan akurasi, terlalu banyak epoch dapat menyebabkan overfitting. Learning rate yang lebih kecil dan ukuran batch yang lebih

				besar juga berkontribusi pada akurasi yang lebih baik, serta menunjukkan potensi aplikasi model dalam mendidik masyarakat tentang tanaman herbal.
3	Ni Putu Dita Ariani Sukma Dewi et al.	Klasifikasi Jenis Daun Tumbuhan Herbal Berdasarkan Lontar Usada Taru Pramana Menggunakan CNN dengan Fitur Fourier Descriptor	2024	Penelitian ini menggunakan dataset TPHerbleaf (50 kelas daun). MobileNet mencapai hasil terbaik (akurasi 82% testing). Pendekatan ini mendukung pelestarian budaya lokal Bali dengan pendekatan CNN modern.
4	Kestrilia R. Prilianti et al.	Ornamental Plant Identification System Using Transfer Learning on CNN	2024	Penelitian ini menggunakan Transfer learning dengan MobileNetV2 dan optimisasi Adagrad memberikan akurasi 88% testing. Sistem dikembangkan ke aplikasi Android bernama PLANTIS, mendukung klasifikasi tanaman hias secara real-time.
5	Dian Budi Elnursa et al.	Sistem Klasifikasi Citra Simplisia Fructus dalam Obat Tradisional Madura Menggunakan Transfer Learning pada CNN	2023	CNN dan transfer learning diterapkan pada simplisia buah (lada, kapulaga, dll). Akurasi mencapai 97% (training), menunjukkan efektivitas CNN dalam klasifikasi bahan obat tradisional.

2.2. Daun Herbal

Daun herbal adalah bagian daun dari tanaman obat yang mengandung senyawa aktif dan digunakan sebagai bahan alami untuk tujuan pengobatan, pencegahan penyakit, atau pemeliharaan kesehatan. Tanaman herbal secara umum dimanfaatkan dalam bentuk segar maupun olahan, dan sering kali menjadi bagian dari pengobatan tradisional, baik secara tunggal maupun dikombinasikan dengan bagian tanaman lain seperti akar, batang, atau rimpang.

Penggunaan daun herbal sebagai bahan dasar dalam pengobatan tradisional telah menjadi bagian tak terpisahkan dari budaya masyarakat Indonesia. Tanaman-tanaman seperti daun sirih, daun sambiloto, dan daun jambu biji kerap digunakan dalam perawatan luka, infeksi ringan, maupun menjaga kesehatan saluran pencernaan. Menurut penelitian oleh (Agustin et al., 2024), konsep Tanaman Obat Keluarga (TOGA) memperkuat pemanfaatan daun herbal sebagai solusi alternatif yang aman, mudah diperoleh, dan ekonomis, khususnya di kalangan masyarakat pedesaan. Tanaman-tanaman ini tidak hanya mengandung senyawa bioaktif seperti flavonoid, alkaloid, dan tanin, tetapi juga terbukti memiliki aktivitas antioksidan dan antibakteri yang tinggi.



Gambar 2.1 Daun Kemangi

Sumber : <https://www.siloamhospitals.com>

Daun kemangi (*Ocimum basilicum*) adalah tanaman herbal yang termasuk dalam keluarga Lamiaceae, dikenal dengan aroma khasnya yang menyegarkan dan sering digunakan sebagai bumbu dalam masakan, terutama di Asia Tenggara. Daun ini memiliki bentuk oval dengan tepi bergerigi dan kaya akan senyawa bioaktif, seperti minyak atsiri yang mengandung eugenol, flavonoid, dan asam fenolik, yang memberikan berbagai manfaat kesehatan, termasuk sifat antioksidan, antibakteri, dan anti-inflamasi. Selain itu, daun kemangi juga dipercaya dapat membantu meredakan stres dan gangguan pencernaan, serta sering digunakan dalam pengobatan tradisional untuk mengatasi berbagai masalah kesehatan, seperti flu dan sariawan. Dengan demikian, daun kemangi tidak hanya berfungsi sebagai bumbu masakan, tetapi juga memiliki potensi terapeutik yang signifikan.



Gambar 2.2 Daun Jambu Biji

Sumber : <https://pertanian.uma.ac.id>

Daun jambu biji (*Psidium guajava*) adalah daun dari tanaman jambu biji yang termasuk dalam keluarga Myrtaceae, dikenal dengan bentuk oval dan permukaan yang halus serta warna hijau tua. Daun ini kaya akan senyawa bioaktif, termasuk flavonoid, tanin, dan asam fenolik, yang memberikan berbagai manfaat kesehatan, seperti sifat antidiabetes, antibakteri, dan anti-inflamasi. Dalam pengobatan

tradisional, daun jambu biji sering digunakan untuk mengatasi masalah pencernaan, seperti diare dan gangguan perut, serta dapat diseduh menjadi teh herbal yang menyehatkan. Selain itu, ekstrak daun jambu biji juga diketahui dapat membantu meningkatkan sistem kekebalan tubuh dan melawan infeksi. Dengan demikian, daun jambu biji tidak hanya berfungsi sebagai bagian dari tanaman buah, tetapi juga memiliki potensi terapeutik yang signifikan dalam menjaga kesehatan.



Gambar 2.3 Daun sirih

Sumber : <https://www.siloamhospitals.com>

Daun sirih (*Piper betle L.*) adalah tanaman merambat yang daunnya telah lama dikenal dan dimanfaatkan dalam pengobatan tradisional Indonesia. Tanaman ini tidak hanya digunakan sebagai bahan kunyahan oleh orang tua zaman dahulu, tetapi juga memiliki kandungan senyawa aktif yang terbukti secara ilmiah memberikan berbagai manfaat kesehatan. Beberapa senyawa penting dalam daun sirih antara lain eugenol yang bersifat antiseptik dan antijamur, flavonoid sebagai antioksidan, serta saponin, tanin, dan karvakrol yang berfungsi sebagai antimikroba dan antiinflamasi. Kombinasi senyawa tersebut menjadikan daun sirih sangat efektif dalam menghambat pertumbuhan bakteri, jamur, serta mempercepat penyembuhan luka. Secara ilmiah, daun sirih terbukti mampu membantu mengatasi

keputihan, mengurangi bau badan dan bau mulut, serta menjaga kesehatan kulit dan organewanitaan. Dalam kehidupan sehari-hari, daun sirih biasanya direbus dan airnya digunakan untuk diminum atau membersihkan bagian tubuh tertentu, dan kini juga telah banyak diolah menjadi produk modern seperti sabun herbal, obat kumur, salep antiseptik, serta minuman kesehatan. Dengan khasiat alami yang dimilikinya, daun sirih menjadi salah satu tanaman herbal lokal yang potensial untuk terus dikembangkan dalam dunia kesehatan modern berbasis kearifan lokal.

2.3. Klasifikasi

Klasifikasi merupakan salah satu tugas utama dalam bidang pembelajaran mesin (*machine learning*) yang bertujuan untuk mengelompokkan data ke dalam kategori tertentu berdasarkan karakteristik atau pola yang terdeteksi. Dalam konteks pengolahan citra digital, klasifikasi digunakan untuk mengenali dan mengelompokkan objek dalam gambar berdasarkan fitur-fitur visual seperti warna, bentuk, dan tekstur. Teknik klasifikasi memainkan peran penting dalam berbagai aplikasi seperti deteksi objek, pengenalan wajah, klasifikasi penyakit tanaman, dan identifikasi produk. Menurut (Nugroho et al., 2025), klasifikasi berbasis citra dapat disempurnakan dengan kombinasi metode ekstraksi fitur dan model pembelajaran mesin seperti *Support Vector Machine* (SVM), *K-Nearest Neighbor* (KNN), dan *Convolutional Neural Network* (CNN).

Dalam implementasinya, proses klasifikasi citra umumnya diawali dengan tahap praproses seperti konversi warna dan penghapusan noise, dilanjutkan dengan ekstraksi fitur yang merepresentasikan informasi penting dari citra, lalu diproses oleh model klasifikasi untuk menghasilkan label atau kategori. Penelitian terbaru

oleh (Abdul Syawal Laan et al., 2025) menunjukkan bahwa pemanfaatan teknologi *Teachable Machine* berbasis pembelajaran mesin mampu menghasilkan sistem klasifikasi citra yang cukup akurat meskipun tanpa pemrograman kompleks, dengan aplikasi pada berbagai bidang seperti deteksi jenis tanah atau produk industri. Hal ini menunjukkan bahwa klasifikasi tidak hanya berguna dalam penelitian, tetapi juga memiliki nilai praktis tinggi dalam dunia nyata.

2.4. Citra Digital

Citra digital adalah representasi visual dari objek dalam bentuk diskret yang tersimpan dalam format digital dan diproses oleh komputer. Setiap citra terdiri atas piksel-piksel yang merepresentasikan informasi visual, seperti warna atau intensitas cahaya, dalam koordinat dua dimensi. Dalam dunia teknologi informasi, citra digital menjadi dasar dalam banyak aplikasi seperti pengenalan wajah, klasifikasi objek, sistem pengawasan, hingga analisis medis. Menurut (Devi & Rosyid, 2022), citra digital mampu menyediakan data visual yang presisi dan dapat dianalisis secara matematis melalui berbagai teknik pengolahan untuk mengekstraksi informasi yang tersembunyi di dalamnya.

Proses pengolahan citra digital modern melibatkan tahapan sistematis seperti prapemrosesan, segmentasi, ekstraksi fitur, hingga klasifikasi berbasis kecerdasan buatan. Dengan kemajuan pesat dalam teknologi machine learning, citra digital kini tidak hanya berfungsi sebagai data visual, tetapi juga sebagai sumber informasi yang dapat dieksplorasi secara komputasional dengan tingkat akurasi tinggi. Teknik-teknik seperti *Convolutional Neural Network (CNN)*, *transformers*, dan *automated feature learning* telah meningkatkan kapabilitas sistem untuk mengenali

pola, mengklasifikasikan objek, serta mendeteksi anomali dalam berbagai domain aplikasi, mulai dari medis hingga industri manufaktur (Obuchowicz et al., 2024).

2.4.1 Citra RGB dan Grayscale

Dalam pengolahan citra digital, pemilihan model warna sangat memengaruhi efektivitas proses analisis dan klasifikasi citra. Model RGB (Red, Green, Blue) adalah format standar untuk citra berwarna, di mana setiap piksel direpresentasikan dalam tiga kanal warna utama. Sebaliknya, citra grayscale hanya menggunakan satu kanal untuk menyatakan intensitas cahaya dari hitam ke putih. Konversi dari RGB ke grayscale dilakukan dengan menggunakan rumus berbobot terhadap masing-masing kanal warna, yang merefleksikan sensitivitas mata manusia. Seperti dijelaskan oleh (Feriska et al., 2024), konversi citra RGB ke grayscale dilakukan untuk memudahkan proses ekstraksi fitur dan normalisasi data citra, karena mengurangi kompleksitas tanpa menghilangkan informasi bentuk penting.

Transformasi citra dari RGB ke grayscale banyak diterapkan sebagai tahap pra-pemrosesan untuk mengurangi kompleksitas data dan mempercepat proses pengolahan. Hal ini dikarenakan konversi ke grayscale memungkinkan pengurangan dimensi dari tiga kanal menjadi satu tanpa kehilangan informasi penting dalam konteks deteksi bentuk atau tekstur. Seperti disampaikan oleh (Pangaribuan et al., 2025) konversi RGB ke grayscale menjadi langkah penting untuk menyederhanakan citra sebelum dilakukan segmentasi atau ekstraksi fitur. Selain itu, (Aaisyah et al., 2025) menekankan bahwa penggunaan grayscale sangat membantu dalam menurunkan beban komputasi dan meningkatkan kecepatan dalam sistem klasifikasi berbasis citra.

2.4.2 Proses Dasar Pengolahan Citra

Pengolahan citra digital merupakan bidang yang berfokus pada manipulasi dan analisis gambar dalam format digital melalui algoritma komputer. Proses dasar dalam pengolahan citra umumnya mencakup beberapa tahapan utama, yaitu:

1. Akuisisi Citra

Tahapan awal dalam pengolahan citra yang bertujuan untuk mendapatkan input citra dari perangkat keras seperti kamera digital atau pemindai. Hasil akuisisi berupa file gambar dalam format tertentu seperti JPEG atau PNG.

2. Pra-pemrosesan

Tahap yang mencakup normalisasi ukuran, konversi warna, hingga pengurangan noise

3. Segmentasi

proses memisahkan objek utama (daun) dari latar belakang citra. Teknik segmentasi yang umum digunakan mencakup thresholding, edge detection (misalnya metode Canny), atau teknik berbasis warna dan kontur. Segmentasi yang tepat akan sangat membantu dalam meningkatkan akurasi sistem klasifikasi.

4. Ekstraksi Fitur

Setelah citra diproses dan disegmentasi, langkah selanjutnya adalah ekstraksi fitur, yaitu pengambilan informasi penting dari objek untuk digunakan sebagai masukan bagi model klasifikasi. Dalam penelitian klasifikasi daun, fitur yang sering digunakan yaitu fitur bentuk, warna dan tekstur.


(Saputra & Ramadhanu, 2025) menyatakan bahwa tahapan dasar ini sangat penting sebagai fondasi dalam membangun sistem klasifikasi citra secara otomatis dan efisien.

Tahapan-tahapan tersebut dirancang untuk mengubah data visual mentah menjadi informasi yang dapat dimengerti mesin, sekaligus memastikan bahwa elemen penting dalam citra tetap terjaga. Menurut (Marpaung et al., 2022), tahapan pengolahan citra dimulai dari proses akuisisi, dilanjutkan dengan segmentasi, ekstraksi fitur, klasifikasi, hingga interpretasi. Pemahaman mendalam terhadap alur ini sangat penting untuk mendukung penerapan teknologi *deep learning* dan *computer vision* dalam bidang pertanian, medis, hingga keamanan.

2.5. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah arsitektur *deep learning* yang banyak digunakan dalam pengolahan citra digital karena kemampuannya mengenali pola visual secara otomatis. CNN memanfaatkan struktur grid dari data citra untuk mengekstraksi fitur secara hierarkis melalui lapisan-lapisan seperti konvolusi, pooling, dan aktivasi. Keunggulan utama CNN terletak pada kemampuannya melakukan ekstraksi fitur langsung dari data mentah tanpa memerlukan perancangan fitur secara manual, sebagaimana dibutuhkan pada metode tradisional. Hal ini membuat CNN sangat efektif dalam tugas-tugas seperti klasifikasi, deteksi objek, dan segmentasi citra (Putrama Alkhairi & Windarto, 2023).

Adapun gambaran dalam tahapan proses klasifikasi citra dengan menggunakan metode CNN dapat dijelaskan pada Gambar 2.4



Gambar 2.4 Tahapan Klasifikasi Citra di CNN (Arsitektur CNN)

Sumber : <https://medium.com>

1. Input Layer, masukan gambar (128x128 piksel,dengan 3 chanel RGB → $128 \times 128 \times 3$).
2. CNN menggunakan filter/kernel kecil (mis. 3×3 atau 5×5) untuk melakukan operasi konvolusi pada citra.
3. Pooling Layers, Layer ini mengurangi dimensi data untuk mempercepat proses komputasi tanpa kehilangan informasi penting.
4. Fully Connected Layers, Layer ini menghubungkan hasil ekstraksi fitur ke Layer output untuk menghasilkan prediksi akhir.
5. Output Layer, menghasilkan similarity score (dalam rentang 0- 1) yang menunjukkan tingkat kesesuaian jenis daun herbal.

Struktur dasar *Convolutional Neural Network* (CNN) mencakup beberapa komponen penting, salah satunya adalah *convolutional layer* yang berperan mengekstraksi fitur spasial dari citra melalui filter berukuran kecil. Lapisan ini memungkinkan jaringan mengenali pola lokal seperti tepi dan tekstur secara otomatis, sekaligus mempertahankan keterhubungan spasial antar piksel. Selama proses pelatihan, bobot filter diperbarui menggunakan algoritma *backpropagation*

agar fitur yang dipelajari semakin sesuai dengan target klasifikasi. Proses ini merupakan inti dari pembelajaran dalam CNN, karena memungkinkan sistem belajar langsung dari data tanpa perlu ekstraksi fitur manual (Widiputra et al., 2021). Secara umum operasi konvolusi dapat ditulis dengan menggunakan rumus pada persamaan.

$$s_t = (x \cdot w)_t \dots \dots \dots (1)$$

Penjelasan :

x = input (misalnya vektor fitur, atau potongan citra pada CNN).

w = bobot (parameter yang dipelajari jaringan).

$x.w$ = perkalian titik (dot product) atau operasi konvolusi antara input dan bobot.

t = index waktu / posisi /neurons tertentu. Jadi S_t adalah skor/aktivitas diposisi t .

Fungsi s_t menghasilkan satu output, yaitu feature map, dengan dua argumen input.

Argumen pertama adalah input, yang dalam hal ini merupakan citra, dan argumen

kedua adalah kernel atau filter yang digunakan dalam operasi konvolusi. Dalam

konteks citra dua dimensi, parameter t dapat dianggap sebagai piksel dan digantikan

dengan i dan j . Oleh karena itu, untuk melakukan operasi konvolusi pada citra

dengan lebih dari satu dimensi, dapat digunakan rumus pada persamaan berikut.

$$S_{(i,j)} = (K * I)_{(i,j)} = \sum_{i=1}^m \sum_{j=1}^n (I_{(i-m,j-n)} * K)_{(m,n)} \dots \dots \dots (2)$$

Penjelasan :

$S_{(i,j)}$ = nilai hasil konvolusi pada koordinat (i,j) di feature map (output).

K = kernel/filter berukuran $m \cdot n$.

I = input (citra asli atau feature map sebelumnya).

$*$ = operasi konvolusi

Rumus untuk menghitung operasi konvolusi dengan i dan j sebagai piksel dari citra. Rumus ini bersifat komutatif dan hanya terjadi saat kernel K dan input i dapat dibalik relatif terhadap satu sama lain. Konvolusi dapat dipandang sebagai perkalian matriks antara input citra dan filter dengan hasil output yang diperoleh melalui dot product.

Setelah hasil dari proses konvolusi diperoleh, data dilanjutkan ke fungsi aktivasi untuk menambahkan sifat non-linear ke dalam model. Fungsi aktivasi yang paling umum digunakan dalam CNN adalah Rectified Linear Unit (ReLU), karena kesederhanaannya dan kemampuannya mempercepat proses pelatihan. ReLU bekerja dengan cara memetakan nilai negatif menjadi nol dan mempertahankan nilai positif, sehingga mempercepat konvergensi dalam pembelajaran jaringan. Namun, salah satu kelemahan ReLU adalah terjadinya fenomena *dying ReLU*, di mana neuron menjadi tidak aktif dan hanya menghasilkan nol untuk semua input. Untuk mengatasi hal ini, digunakan varian fungsi aktivasi seperti Leaky ReLU, yang tetap memberikan nilai output kecil untuk input negatif agar aliran informasi tetap berlangsung selama pelatihan (Ramadhani et al., 2024). ReLU merupakan lapisan aktivasi menggunakan persamaan.

$$f(x) = \max(0, x) \dots \dots \dots (3)$$

penjelasan :


Persamaan ini adalah fungsi aktivasi ReLU (Rectified Linear Unit).

Artinya :

- a. Jika $x > 0$, maka $f(x) = x$
- b. Jika $x \leq 0$, maka $f(x) = 0$

Jadi ReLU hanya melewati nilai positif, sedangkan nilai negatif diubah menjadi 0.

Salah satu komponen penting dalam arsitektur Convolutional Neural Network (CNN) adalah pooling layer, yang berfungsi untuk mereduksi dimensi spasial dari fitur yang dihasilkan oleh lapisan konvolusi. Dengan cara ini, model menjadi lebih efisien tanpa kehilangan informasi penting. Teknik umum yang digunakan adalah *max pooling* dan *average pooling*, di mana keduanya membantu menyederhanakan representasi data dan mempercepat proses pelatihan. Selain itu, pooling juga mengurangi jumlah parameter yang dilatih, sehingga dapat mengurangi risiko overfitting dan meningkatkan ketahanan model terhadap variasi posisi objek dalam gambar (Alifian et al., 2023). Ilustrasi pooling layer dengan operasi average pooling dapat dilihat pada Gambar 2.5




Gambar 2.5 Ilustrasi Proses Average Pooling

Sumber : <https://medium.com>

Setelah proses ekstraksi fitur dari lapisan-lapisan awal CNN selesai, hasilnya kemudian diteruskan ke *fully connected layer* sebagai tahap akhir klasifikasi. Pada lapisan ini, seluruh neuron saling terhubung untuk menyatukan informasi dari fitur yang telah diolah. Proses ini menghasilkan output berupa nilai probabilitas untuk tiap kelas melalui fungsi aktivasi *softmax*, yang berfungsi sebagai pengklasifikasi

akhir. Meskipun lapisan ini mengandung banyak parameter, keberadaannya sangat penting karena bertanggung jawab mengubah fitur numerik hasil ekstraksi menjadi keputusan klasifikasi yang konkret (Auni & Sugiharti, 2025). Gambar 2.6 merupakan tampilan Fully Connected Layer serta output layer.



Gambar 2.6 Ilustrasi Proses Fully Connected Layer
Sumber : <https://warstek.com>

Dalam proses pelatihan CNN, penggunaan *loss function* seperti *categorical cross-entropy* bertujuan untuk mengukur seberapa besar perbedaan antara output prediksi dan label sebenarnya. Nilai kesalahan ini digunakan sebagai acuan untuk memperbarui bobot jaringan melalui algoritma *backpropagation*. Melalui proses ini, CNN belajar untuk meminimalkan kesalahan dengan menyesuaikan parameter-parameter jaringan secara iteratif. Untuk mengoptimalkan pembaruan bobot, digunakan algoritma seperti *Stochastic Gradient Descent (SGD)* atau *Adam*, yang terbukti efektif dalam mempercepat konvergensi model dan meningkatkan akurasi prediksi (Putrama Alkhairi & Windarto, 2023).

Dalam klasifikasi citra daun, Convolutional Neural Network (CNN) terbukti sangat efektif karena kemampuannya dalam mengenali berbagai fitur visual penting seperti bentuk, pola, dan warna daun, termasuk tanda-tanda penyakit tanaman. Keunggulan CNN dibanding pendekatan konvensional terletak pada

kemampuannya melakukan klasifikasi langsung dari citra mentah, tanpa memerlukan segmentasi atau ekstraksi fitur manual.

2.6. Hyperparameter Tuning

Dalam konteks *machine learning*, performa sebuah model sangat dipengaruhi oleh pemilihan dan penyesuaian hyperparameter. Hyperparameter adalah parameter yang tidak dipelajari secara langsung dari data, tetapi ditentukan sebelum proses pelatihan dimulai, seperti jumlah estimators pada Random Forest atau learning rate pada algoritma Gradient Boosting. Menurut Nugraha dan Sasongko (2022), *“nilai dari hyperparameter dapat memengaruhi performa model secara signifikan karena menentukan arah pembelajaran dari model tersebut”* (Nugraha & Sasongko, n.d.). Oleh karena itu, tuning hyperparameter menjadi proses penting untuk meningkatkan akurasi, mengurangi kesalahan, dan mencegah overfitting.

Sejumlah metode telah dikembangkan untuk melakukan tuning, termasuk Grid Search, Random Search, dan Bayesian Optimization. Grid Search melakukan pencarian menyeluruh atas kombinasi parameter yang memungkinkan, sedangkan Random Search memilih parameter secara acak dalam ruang pencarian. Dalam penelitian oleh Haryanto dan Azhari (2024), tuning hyperparameter pada model RNN-LSTM terbukti *“mampu meningkatkan akurasi prediksi harga komoditas bawang putih secara signifikan dengan meminimalkan nilai RMSE”* (Azhari & Haryanto, 2024). Hal ini menunjukkan bahwa pemilihan parameter yang tepat tidak hanya memperbaiki performa, tetapi juga meningkatkan efisiensi waktu komputasi.

Penerapan hyperparameter tuning tidak hanya terbatas pada domain prediksi harga atau klasifikasi umum, tetapi juga pada bidang kesehatan dan sosial.

Misalnya, dalam mendeteksi kelangsungan hidup pasien gagal jantung, Sitanggang dan Sitompul (2024) menyatakan bahwa *“proses tuning menghasilkan model Random Forest dengan akurasi lebih tinggi dibandingkan model default, sehingga lebih layak digunakan dalam pengambilan keputusan klinis”* ((Awal Kelangsungan Hidup Pasien Gagal Jantung et al., 2024). Oleh sebab itu, tuning merupakan tahapan krusial yang tidak boleh dilewatkan dalam pipeline pengembangan model pembelajaran mesin, terutama jika digunakan untuk sistem berbasis keputusan yang kritis.

2.7. Random Search

Random Search merupakan salah satu metode pencarian dalam proses *hyperparameter tuning* yang bekerja dengan cara memilih kombinasi parameter secara acak dari ruang pencarian yang telah ditentukan. Tidak seperti Grid Search yang mengevaluasi seluruh kemungkinan secara menyeluruh, Random Search hanya melakukan sampling acak dan mengevaluasi sebagian kombinasi. Hal ini menjadikannya lebih efisien dalam hal waktu dan sumber daya, terutama ketika hanya sebagian kecil dari parameter yang benar-benar berpengaruh besar terhadap kinerja model. Dalam konteks model *deep learning* seperti Convolutional Neural Network (CNN), Random Search sering digunakan untuk menyetel parameter seperti *learning rate*, *batch size*, dan jumlah *epoch* secara cepat dan adaptif tanpa perlu memeriksa setiap kemungkinan kombinasi (Xu et al., 2023).

Random Search memanfaatkan distribusi probabilitas untuk memilih nilai dari setiap hyperparameter. Nilai-nilai tersebut kemudian diuji pada model, dan hasilnya dievaluasi menggunakan metrik kinerja tertentu seperti akurasi atau loss.

Proses ini diulang hingga tercapai performa optimal atau hingga batas iterasi terpenuhi. Pendekatan ini terbukti efektif dalam banyak studi karena memberikan peluang yang cukup besar untuk menemukan konfigurasi optimal tanpa memerlukan eksplorasi menyeluruh. Menurut (Xu et al., 2023.), metode ini menghasilkan performa yang sebanding dengan Grid Search dalam eksperimen CNN untuk data spasio-temporal, namun dengan biaya komputasi yang lebih rendah. Oleh karena itu, Random Search menjadi pilihan yang praktis dan adaptif untuk eksperimen skala menengah hingga besar.

2.8. Tools Pendukung

Dalam implementasi proyek menggunakan metode Convolutional Neural Network (CNN), diperlukan memilih bahasa pemrograman yang tidak hanya stabil dan fleksibel, tetapi juga dilengkapi dengan berbagai alat bantu seperti pustaka (library). Hal ini akan sangat membantu dalam mempercepat dan mempermudah proses implementasi. Saat ini, Python menjadi pilihan utama yang memenuhi semua kriteria tersebut. Untuk menerapkan metode CNN, terdapat sejumlah pustaka Python yang populer dan sering digunakan, antara lain TensorFlow, Keras, Scikit-learn, NumPy, Pandas, dan Matplotlib.

2.8.1 Python

Python adalah bahasa pemrograman tingkat tinggi yang sangat populer, dikenal karena sintaksnya yang sederhana dan kemampuannya dalam menangani berbagai tugas, mulai dari pengembangan situs web hingga analisis data dan pembelajaran mesin (Ritonga et al., 2023). Diciptakan oleh Guido van Rossum dan

diluncurkan pertama kali pada tahun 1991, Python dirancang agar mudah dipahami, sehingga memungkinkan pengembang untuk mengekspresikan ide-ide mereka dengan lebih sedikit baris kode dibandingkan dengan bahasa lain seperti C++ atau Java. Bahasa ini mendukung berbagai paradigma pemrograman, termasuk pemrograman berorientasi objek, prosedural, dan fungsional, menjadikannya sangat fleksibel untuk berbagai aplikasi. Selain itu, Python memiliki komunitas yang aktif dan ekosistem pustaka yang luas.

Ada banyak library dan library-library ini memiliki fitur yang memadai untuk mempermudah proses implementasi dan pengembangan proyek CNN (Raihan et al., 2021) yaitu sebagai berikut :

1. Tensorflow adalah platform *open source end-to-end* yang dibuat dan dikembangkan oleh Google Brain untuk mendukung Machine Learning. Tensorflow memiliki alat, pustaka, dan sumber daya yang komprehensif dan fleksibel yang memungkinkan penelitian menggunakan Machine Learning yang mutakhir dan developer dengan mudah membangun dan menerapkan aplikasi yang didukung Machine Learning. Tensorflow dapat digunakan dengan bahasa pemrograman Python yang stabil. Tensorflow menawarkan pemrograman yang melakukan berbagai macam tugas ML/DL (regresi dan klasifikasi).
2. Keras adalah sebuah API (*Application Programming Interface*) tingkat tinggi dari Tensorflow yang dibuat oleh François Chollet, seorang engineer di Google. Keras dirancang agar mudah dipelajari dan digunakan, terutama bagi para peneliti, sehingga mereka dapat fokus pada eksperimen dan bukan pada penggunaan library. Keras dapat digunakan untuk membangun

CNN, seperti melakukan one-hotencoding pada label citra, membuat arsitektur CNN, menggunakan arsitektur CNN populer yang tersedia, melakukan plotting model CNN, memuat dataset citra ke dalam arsitektur CNN, serta melakukan training dan testing model CNN untuk menghasilkan evaluasi seperti akurasi dan loss. Selain itu, Keras juga dapat digunakan untuk menyimpan dan mengakses model CNN dalam format h5.

3. Sklearn Sebuah tools untuk Machine Learning yang digunakan untuk berbagai model statistik seperti classification, regression, clustering, dan dimensionality reduction. Dalam implementasi CNN, Sklearn dapat digunakan sebagai alat untuk menerapkan teknik K-Fold Cross Validation pada dataset, membuat Confusion Matrix, dan Classification Report.
4. Numpy Sebuah library yang berfungsi untuk memanipulasi dan mengolah array serta matriks. Salah satu contoh penggunaannya dalam CNN adalah dengan melakukan reshape pada dimensi citra, menghitung rata-rata dan standar deviasi akurasi model CNN, dan melakukan pengolahan data.
5. Pandas Berguna untuk melakukan manipulasi dan analisis data. Dalam konteks penggunaan pada CNN, contohnya adalah menyimpan riwayat pelatihan model (dalam bentuk akurasi dan loss) ke dalam sebuah tabel CSV.
6. Matplotlib Digunakan untuk membuat grafik dan visualisasi data. Contoh penggunaannya pada CNN adalah memplot dataset beserta labelnya dan memplot hasil pelatihan dan pengujian model CNN ke dalam grafik untuk memudahkan pemahaman dan analisis.

BAB III

METODOLOGI PENELITIAN

3.1. Metode penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk melakukan klasifikasi citra daun herbal menggunakan algoritma Convolutional Neural Network (CNN). Objek dalam penelitian ini terdiri dari tiga jenis daun herbal, yaitu daun sirih, daun kemangi, dan daun jambu biji. Seluruh citra daun diperoleh melalui pencarian gambar dari internet yang relevan dan memiliki kualitas visual yang memadai untuk kebutuhan pelatihan model. Sebelum digunakan dalam pelatihan, gambar-gambar tersebut melalui proses prapengolahan (*preprocessing*) yang mencakup normalisasi ukuran citra, konversi ke format RGB, augmentasi data seperti rotasi, flipping, zoom, dan translasi untuk meningkatkan jumlah data dan mengurangi overfitting.

Model CNN dirancang untuk mengenali pola visual yang khas dari masing-masing jenis daun. Arsitektur CNN meliputi beberapa lapisan konvolusi, lapisan pooling, dan fully connected layer sebagai bagian dari klasifikasi. Dalam rangka memperoleh model dengan performa optimal, penelitian ini menerapkan teknik *hyperparameter tuning* menggunakan metode *Random Search*. Proses ini dilakukan dengan mengeksplorasi berbagai kombinasi nilai hyperparameter seperti jumlah filter, ukuran kernel, *learning rate*, batch size, dan jumlah epoch secara acak dalam ruang pencarian yang telah ditentukan. Evaluasi model dilakukan dengan menggunakan metrik akurasi, precision, recall, dan F1-score, yang dihitung berdasarkan hasil klasifikasi pada data uji. Hasil dari penelitian ini diharapkan

mampu menunjukkan efektivitas CNN dalam klasifikasi citra daun herbal serta efisiensi metode Random Search dalam menemukan konfigurasi hyperparameter terbaik.

3.2. Instrumen Penelitian


Hasil pengembangan dalam penelitian ini melibatkan pemanfaatan berbagai instrumen dan spesifikasi teknis yang mendukung kelancaran proses penelitian. Komponen tersebut meliputi perangkat keras, perangkat lunak, serta sistem operasi yang digunakan sebagai dasar dalam pengembangan aplikasi. Berikut akan dijelaskan secara rinci spesifikasi yang diterapkan dalam penelitian ini.

Tabel 3. 1 Instrumen Penelitian

Instrumen	Spesifikasi
Processor	11th Gen Intel(R) Core(TM) i3-1115G4 @ 3.00GHz (4 CPUs), ~3.0GHz
Memory	8 Gb
Solid State Drive	256 Gb
Series	Acer Aspire A514-54
Microsoft Word	2021
Python Version	3.10

3.3. Alur penelitian

Dalam proses penelitian yang dilakukan yaitu membangun model klasifikasi Daun Herbal dengan menggunakan algoritma Convolutional Neural Network (CNN) dan hyperparameter tuning dengan metode Random Search , maka tahapan proses dari penelitian ini dapat dilihat berdasarkan flowchart dibawah ini :



Gambar 3.1 Alur Penelitian

Adapun penjelasan mengenai perancangan analisis pada *flowchart* diatas adalah sebagai berikut :

1. Pengumpulan Data

Dataset citra daun tanaman herbal dikumpulkan dari sumber dataset publik maupun hasil dokumentasi langsung. Data kemudian diklasifikasi berdasarkan jenis tanaman, dan dilakukan *labeling* untuk setiap gambar.

Tahapan ini juga mencakup validasi format file, ukuran gambar, dan keseimbangan kelas.

2. Pra-pemrosesan data

Citra yang telah dikumpulkan akan diproses lebih lanjut agar siap masuk ke dalam model CNN. Langkah-langkah umum pra-pemrosesan mencakup :

- a. Resize gambar ke dimensi seragam.
- b. Normalisasi piksel (misalnya skala 0-1).
- c. Augmentasi seperti rotasi, flipping, atau zoom untuk menambah keragaman data.
- d. Split dataset menjadi data pelatihan dan data pengujian (misalnya 80:20).

3. Pembangunan Model

Di tahap ini, arsitektur awal CNN dibangun. Model mencakup layer konvolusi, pooling, flattening, dan fully connected. Belum dilakukan optimasi pada parameter ini masih baseline. Tujuannya adalah menyediakan struktur dasar sebelum dilakukan tuning.

4. Hyperparameter Tuning

Model CNN awal kemudian disempurnakan dengan mencari konfigurasi hyperparameter terbaik. Random Search digunakan untuk mengeksplorasi nilai hyperparameter secara acak seperti :

- a. Learning rate
- b. Batch size
- c. Jumlah epoch
- d. Optimizer

- e. Jumlah filter atau neuron di setiap layer

Random Search lebih efisien dibandingkan Grid Search saat ruang pencarian besar. Nilai terbaik dipilih berdasarkan akurasi validasi atau skor evaluasi lainnya.

5. Pelatihan Model

Model dilatih kembali menggunakan konfigurasi hyperparameter terbaik hasil Random Search. Proses ini mencakup iterasi (epoch) berulang, dan model belajar mengenali pola fitur pada citra daun dari data training.

6. Evaluasi Model


Setelah pelatihan, model diuji menggunakan data uji yang belum pernah dilihat sebelumnya. Evaluasi dilakukan menggunakan metrik seperti :

- a. Akurasi
- b. Precision
- c. Recall
- d. F1-score
- e. Confusion matrix

Hasil evaluasi akan menunjukkan seberapa baik model dalam mengklasifikasi daun herbal secara otomatis.

3.4. Arsitektur CNN

Adapun arsitektur CNN dapat di jelaskan dari flowchart dibawah ini :



Gambar 3.2 Arsitektur CNN

1. Input Layer

Menerima citra dalam format matriks piksel, misalnya 28×28 grayscale atau $224 \times 224 \times 3$ RGB.

2. Convolutional Layer

CNN menggunakan filter/kernel kecil (mis. 3×3 atau 5×5) untuk melakukan operasi konvolusi pada citra.

3. Relu

Biasanya menggunakan ReLU (Rectified Linear Unit) untuk menambahkan non-linearitas.

4. Pooling Layer

Mengurangi dimensi *feature map* sambil mempertahankan informasi penting.

5. Fully Connected Layer


Mengubah *feature map* menjadi vektor dan menghubungkannya ke lapisan klasifikasi.

6. Output Layer

Menggunakan Softmax (untuk multi-class) atau Sigmoid (untuk binary) untuk menghasilkan probabilitas kelas.

3.5. Perancangan Model

Adapun perancangan model Hyperparameter tuning dapat di jelaskan dari flowchart dibawah ini :



Gambar 3.3 Perancangan model

1. Menentukan rentang nilai hyperparameter

Tahap awal ini adalah inti dari metode *Random Search*. Sistem secara acak memilih kombinasi hyperparameter seperti:

- a. Jumlah filter pada layer convolution
- b. Ukuran kernel (misalnya 3x3, 5x5)
- c. Fungsi aktivasi (ReLU, sigmoid)
- d. Learning rate
- e. Batch size
- f. Jumlah epoch

2. Memilih nilai parameter acak

Dengan kombinasi hyperparameter yang telah diacak, sistem membangun struktur CNN. Ini mencakup layer convolution, pooling, flattening, dan fully connected.

3. CNN

Model dilatih menggunakan data pelatihan. Proses ini melibatkan forward propagation dan backpropagation untuk memperbarui bobot sesuai dengan nilai loss.

4. Menghitung nilai validasi akurasi

Model diuji menggunakan data validasi. Evaluasi ini dilakukan untuk mencatat performa berdasarkan metrik seperti akurasi, precision, recall, atau loss. Nilai ini akan digunakan untuk menilai kualitas dari kombinasi parameter yang dipakai.

5. Iterasi maksimal

Sistem mengecek apakah jumlah iterasi/random sample yang telah dicoba sudah mencapai batas maksimum.

- a. Jika belum, sistem kembali ke awal untuk mencoba kombinasi baru.
- b. Jika sudah, lanjut ke tahap berikutnya.

6. Memilih nilai hyperparameter dengan validasi akurasi tertinggi

Dari semua kombinasi yang telah dicoba, sistem memilih yang memberikan performa terbaik (misalnya akurasi validasi tertinggi).

7. Menyimpan model

Nilai ini akan digunakan untuk menilai kualitas dari kombinasi parameter yang dipakai.

BAB IV

HASIL DAN PEMBAHASAN

Hasil dari Klasifikasi Daun Herbal Berbasis Citra Menggunakan *Convolutional Neural Network* (CNN) Dengan *Hyperparameter Tuning Random Search* dan tahapan metode menggunakan python dapat dilihat sebagai berikut:

4.1. Tujuan Program

Melakukan klasifikasi gambar daun herbal dengan model CNN (Convolutional Neural Network) dan Hyperparameter Tuning menggunakan Random Search ke dalam 3 kelas:

1. Jambu Biji
2. Kemangi
3. Sirih

jambu_biji	01/07/2025 17:06	File folder
kemangi	01/07/2025 17:06	File folder
sirih	01/07/2025 17:06	File folder

Gambar 4.1. Folder Dataset

Tabel 4.1 Pseudocode Pembacaan Folder

Pseudocode 1: Membaca Folder untuk Dataset

Input: Membaca dataset ketiga daun herbal

Output: Menampilkan isi data ketiga daun herbal

1. *if not os.path.exists("dataset"):*

// os.path.exists(path) adalah fungsi dari modul os yang digunakan untuk mengecek apakah suatu file atau folder dengan nama/path tertentu ada. not digunakan untuk membalikkan nilai logika. Jika folder ada os.path.exists("dataset") mengembalikan True, lalu not True = False, sehingga blok kode tidak dijalankan. Jika folder tidak ada, os.path.exists("dataset") mengembalikan False, lalu not False = True, sehingga blok kode dijalankan.

2. ***raise FileNotFoundError("Folder 'dataset/' tidak ditemukan!")***

// raise digunakan untuk memicu/menghasilkan sebuah error secara sengaja.

FileNotFoundError adalah tipe error bawaan Python yang biasanya digunakan ketika file atau folder yang dibutuhkan tidak ditemukan.

Pesan "Folder 'dataset/' tidak ditemukan!" adalah informasi tambahan untuk memberi tahu pengguna atau developer tentang apa yang salah.

4.2. Parameter Acak

Parameter acak yang peneliti gunakan disajikan pada Tabel 4.1 dengan parameter dan nilai yang ditentukan.

Tabel 4.2 Parameter Acak

Parameter	Nilai yang Dicoba	Keterangan
num_filters	32, 64	32: Filter dipelajari dari data 64: Seluruh Filter
kernel_size	3, 5	3: Pixel 3x3 (pixel minimal) 5: Pixel 5x5 (pixel maximal)
dropout rate	0.3, 0.5, 0.7	Nilai rating dropout
lr (learning rate)	0.001, 0.0005, 0.0001	Nilai learning rate
epochs	10, 15, 20	Perulangan 10 hingga 20
batch_size	32	Jumlah sampel (data) yang diproses sekaligus dalam satu langkah

Tabel 4.3 Pseudocode Parameter Acak

Pseudocode 2: Parameter Acak

Input: Filter, Kernel Size, Dropout Size, Learning Rate, Epoch, Batch Size

Output: Kelas Param Distance

1. *param_dist* = {

//Kelas bernama param_dist

2. *'num_filters': [32, 64],*

//Menentukan jumlah filter pada layer konvolusi CNN.

Dampak : [32]: Lebih ringan dan cepat, cocok untuk eksperimen awal atau dataset kecil. [64] Lebih banyak filter, menangkap fitur lebih kompleks, tetapi lebih berat.

3. 'kernel_size': [3, 5],

//Ukuran filter konvolusi dalam piksel

//3: Pixel 3x3 umum digunakan untuk efisiensi dan hasil baik

//5: Pixel 5x5 lebih besar sehingga menangkap pola lebih luas, tetapi lebih lambat.

4. 'dropout_rate': [0.3, 0.5, 0.7],

//Mengontrol proporsi neuron yang di-nonaktifkan saat pelatihan untuk mengurangi overfitting.

//0.3 rata-rata 30% neuron di-drop (ringan).

//0.5 rata-rata 50% neuron di-drop (standar).

//0.7 rata-rata 70% neuron di-drop (sangat agresif, untuk mencegah overfitting parah).

5. 'lr': [1e-3, 5e-4, 1e-4],

//Menentukan learning rate atau kecepatan pembelajaran optimizer.

//Learning Rate: 0.001, Cepat belajar, tetapi bisa kurang stabil.

// Learning Rate: 0.0005, Keseimbangan antara kecepatan dan stabilitas.

// Learning Rate: 0.0001, Stabil tetapi lambat.

6. 'epochs': [10, 15, 20],

// Menentukan berapa kali seluruh dataset dilatih ulang selama proses training.

// [10] Cepat selesai, cocok untuk tes awal.

//[20] Lebih lama, memberi model lebih banyak kesempatan belajar.

7. 'batch_size': [32] }

// Jumlah sampel yang diproses sekaligus dalam satu langkah pembaruan bobot.

// Nilai umum: 32 adalah pilihan standar yang seimbang antara kecepatan dan akurasi.

4.3. Contoh Proses

Pada iterasi ke-1, parameter terpilih secara acak:

1. Model CNN:

Berikut adalah model CNN yang digunakan di python dan pada penelitian penulis:

Tabel 4.4 Pseudocode Model CNN

Pseudocode 3: Membuat model CNN

Input: Dataset daun herbal

Output: Menampilkan hasil model CNN

1. *model = models.Sequential([*

//Membuat model Sequential, yaitu model neural network berlapis linear

2. *layers.Input(shape=(128, 128, 3)),*

//Layer input untuk gambar berukuran 128x128 piksel dengan 3 channel warna (RGB)

3. *layers.Conv2D(num_filters, (kernel_size, kernel_size), activation='relu'),*

//Layer konvolusi pertama dengan filter sebanyak `num\_filters` dan aktivasi ReLU

4. *layers.MaxPooling2D(2, 2),*

//Layer pooling pertama untuk mengurangi dimensi fitur (downsampling)

5. *layers.Conv2D(num_filters * 2, (kernel_size, kernel_size), activation='relu'),*

//Layer konvolusi kedua, filter dikali 2 untuk menangkap fitur yang lebih kompleks

6. *layers.MaxPooling2D(2, 2),*

//Layer pooling kedua

7. *layers.Conv2D(num_filters * 4, (kernel_size, kernel_size), activation='relu'),*

//Layer konvolusi ketiga, filter dikali 4 untuk fitur yang lebih dalam

8. *layers.MaxPooling2D(2, 2),*

//Layer pooling ketiga

```

9. layers.Flatten(),
    //Mengubah fitur hasil konvolusi menjadi vektor 1 dimensi
10. layers.Dense(128, activation='relu'),
    //Fully connected layer dengan 128 neuron dan aktivasi ReLU
11. layers.Dropout(dropout_rate),
    //Dropout untuk mencegah overfitting dengan mengabaikan sebagian neuron
    saat training
12. layers.Dense(train_gen.num_classes, activation='softmax')
    //Output layer dengan jumlah neuron sesuai jumlah kelas dan aktivasi
    softmax untuk klasifikasi multi-kelas
13. )
    //Penutup struktur model
14. return model
    //Mengembalikan model CNN yang telah dibangun

```

2. Lalu model dilatih

Setelah 5 epoch, akurasi validasi (val_accuracy) tiap epoch:

Tabel 4.5. Model Latih

Epoch	Val Accuracy
1	0.78
2	0.82
3	0.85
4	0.86
5	0.85

Maka $\text{val_acc} = \max(\text{history.history}['\text{val_accuracy}']) = 0.86$

Tabel 4.6 Pseudocode Nilai Akurasi

Pseudocode 4: Menghasilkan Nilai Akurasi

Input: Dataset daun herbal

Output: Menampilkan nilai akurasi

```

1. val_acc = max(history.history['val_accuracy'])
    //Mengambil nilai akurasi validasi tertinggi dari hasil pelatihan model
2. print(f"👍 Val Accuracy: {val_acc:.4f}")

```

//Menampilkan nilai akurasi validasi terbaik dengan 4 angka di belakang koma

3. Bandingkan Semua Iterasi

Misal hasil dari 3 iterasi random search:

Tabel 4.7 Perbandingan Iterasi

Iterasi	num filters	kernel size	dropout	lr	val acc
1	32	3	0.5	0.001	0.86
2	64	5	0.7	0.01	0.73
3	32	3	0.3	0.0001	0.79

Maka:

`best_val_acc = 0.86`

Tabel 4.8 Pseudocode Perbandingan Iterasi

Pseudocode 5: Menghasilkan Perbandingan Iterasi

Input: Dataset daun herbal

Output: Menampilkan nilai perbandingan iterasi

1. `Model_best, best_params = random_search(n_iter=10)`

//Melakukan pencarian hyperparameter terbaik sebanyak 10 iterasi menggunakan Random Search

2. `print("\n☑ Best Parameters Ditemukan:")`

//Menampilkan teks konfirmasi bahwa parameter terbaik telah ditemukan

3. `print(best_params)`

//Menampilkan hasil kombinasi parameter terbaik

4. `model_best.save("model_daun_herbal_best.h5")`

//Menyimpan model CNN terbaik ke dalam file HDF5 bernama 'model_daun_herbal_best.h5'

5. `print("💾 Model disimpan sebagai 'model_daun_herbal_best.h5'")`

//Menampilkan pesan bahwa model berhasil disimpan

6. `loss, acc = model_best.evaluate(val_gen, verbose=0)`

//Melakukan evaluasi model terbaik terhadap data validasi dan menghitung nilai loss dan akurasi

4.4. Evaluasi Akhir

Setelah `model_best` disimpan dan diuji:

Tabel 4.9 Pseudocode Evaluasi Akhir

Pseudocode 6: Menghasilkan Nilai Akurasi

Input: Dataset daun herbal

Output: Menampilkan evaluasi akhir

loss, acc = model_best.evaluate(val_gen, verbose=0)

//Menghitung evaluasi akhir

Output:

loss = 0.23

acc = 0.77

Artinya: model kamu memiliki akurasi validasi akhir 77%.

4.5. Prediksi Gambar Baru

Pseudocode `jambu1.jpg` diprediksi:

Tabel 4.10 Pseudocode Evaluasi Akhir

Pseudocode 7: Prediksi Gambar

Input: Gambar Uji

Output: Menampilkan prediksi gambar

1. if not os.path.exists("jambu1.jpg"):

//Memeriksa apakah file gambar 'jambu1.jpg' tersedia

2. raise FileNotFoundError("File 'jambu1.jpg' tidak ditemukan!")

//Menampilkan error jika file tidak ada

3. img = cv2.imread("jambu1.jpg")

//Membaca gambar menggunakan OpenCV

4. img = cv2.resize(img, img_size)

//Mengubah ukuran gambar sesuai ukuran input model

5. img = img / 255.0





//Normalisasi piksel ke rentang 0–1




```




6. img = np.expand_dims(img, axis=0)
    //Menambahkan dimensi batch agar sesuai dengan input model
    (1, 128, 128, 3)
7. pred = model_best.predict(img)
    //Melakukan prediksi menggunakan model terbaik (output berupa vektor
    probabilitas kelas)
8. pred_class = np.argmax(pred)
    //Mengambil indeks kelas dengan probabilitas tertinggi
9. confidence = pred[0][pred_class] * 100
    //Menghitung tingkat kepercayaan prediksi (dalam persen)
10. label_map = train_gen.class_indices
    //Mengambil pemetaan label dari generator pelatihan
11. inv_map = {v: k for k, v in label_map.items()}
    //Membalik mapping: dari indeks ke label nama kelas
12. label = inv_map[pred_class]
    //Mengambil nama kelas berdasarkan hasil prediksi
13. for i, p in enumerate(pred[0]):
    print(f"{inv_map[i]}: {p*100:.2f}%")
    //Menampilkan probabilitas setiap kelas
14. plt.imshow(cv2.cvtColor(cv2.imread("jambu1.jpg"),
cv2.COLOR_BGR2RGB))
    //Menampilkan gambar yang diprediksi dengan konversi warna BGR ke RGB
15. plt.title(f"Prediksi: {label} ({confidence:.2f}%)")
    //Menampilkan label hasil prediksi dan confidence pada judul gambar
16. plt.axis("off")
    //Menghilangkan sumbu gambar
17. plt.show()
    //Menampilkan visualisasi akhir




```




Tabel 4.11. Hasil Prediksi



Pengujian	Gambar	Daun Jambu Biji	Daun Kemangi	Daun Sirih
1	Daun Jambu Biji:  Daun Kemangi:  Daun Sirih: 	94,24	88,22	98,56
2	Daun Jambu Biji : 	95,70	96,60	86,34



	Daun Kemangi :  Daun Sirih : 			
3	Daun Jambu Biji :  Daun Kemangi : 	98,26	81,69	98,94



	Daun Sirih : 			
4	Daun Jambu Biji :  Daun Kemangi :  Daun Sirih : 	98,05	82,72	97,93

5	Daun Jambu Biji :  Daun Kemangi :  Daun Sirih : 	59,27	89,92	89,95
6	Daun Jambu Biji : 	90,66	86,12	90,25

	Daun Kemangi :  Daun Sirih : 			
7	Daun Jambu Biji :  Daun Kemangi : 	77,01	94,09	88,43

	Daun Sirih : 			
8	Daun Jambu Biji :  Daun Kemangi :  Daun Sirih : 	96,65	85,87	87,30

9	Daun Jambu Biji :  Prediksi: jambu_biji (97.16%) Daun Kemangi :  Prediksi: kemangi (80.47%) Daun Sirih :  Prediksi: sirih (94.15%)	97,36	80,47	94,15
10	Daun Jambu Biji :  Prediksi: jambu_biji (60.20%)	60,20	91,86	90,08

	Daun Kemangi :  Daun Sirih : 			
Akurasi Rata-Rata		86,14	95,23	95,97

Keterangan:

1. Pengujian 1

- Daun Jambu Biji: 94,24%
- Daun Kemangi: 88,22%
- Daun Sirih: 98,56%

→ Model mampu mengenali ketiga jenis daun dengan sangat baik, terutama daun sirih dengan akurasi hampir sempurna.

2. Pengujian 2

- Daun Jambu Biji: 95,70%
- Daun Kemangi: 96,60%
- Daun Sirih: 86,34%

→ Semua jenis daun dikenali dengan sangat akurat, Namun di pengujian kali ini hasil akurasi daun sirih menurun.

3. Pengujian 3

- a. Daun Jambu Biji: 98,26%
- b. Daun Kemangi: 81,69%
- c. Daun Sirih: 98,94%

→ Meskipun akurasi masih cukup tinggi, akurasi untuk daun kemangi sedikit menurun kemungkinan disebabkan oleh kemiripan fitur dengan kelas lainnya.

4. Pengujian 4

- a. Daun Jambu Biji: 98,05%
- b. Daun Kemangi: 82,72%
- c. Daun Sirih: 97,93%

→ Akurasi tetap tinggi untuk daun jambu biji dan sirih. Daun kemangi menunjukkan fluktuasi, walau masih dalam rentang akurasi yang layak.

5. Pengujian 5

- a. Daun Jambu Biji: 59,27%
- b. Daun Kemangi: 89,92%
- c. Daun Sirih: 89,95%

→ Terjadi penurunan signifikan pada pengenalan daun jambu biji, kemungkinan besar akibat noise atau kemiripan fitur antar kelas. Ini mencerminkan titik lemah model pada kelas tersebut.

6. Pengujian 6

- a. Daun Jambu Biji: 90,66%
- b. Daun Kemangi: 86,12%

c. Daun Sirih: 90,25%

→ Model menunjukkan kestabilan dengan akurasi yang baik untuk ketiga jenis daun. Tidak ada penurunan performa signifikan.

7. Pengujian 7

a. Daun Jambu Biji: 77,01%

b. Daun Kemangi: 94,09%

c. Daun Sirih: 88,43%

→ Akurasi daun jambu biji kembali menurun, menunjukkan ketidak konsistenan pengenalan pada kelas ini. Namun, daun kemangi dan sirih tetap dikenali dengan baik.

8. Pengujian 8

a. Daun Jambu Biji: 96,65%

b. Daun Kemangi: 85,87%

c. Daun Sirih: 87,30%

→ Performa model secara umum kembali meningkat. Daun jambu biji menunjukkan kestabilan, sementara daun kemangi sedikit meningkat meskipun belum mencapai performa tertingginya.

9. Pengujian 9

a. Daun Jambu Biji: 97,36%

b. Daun Kemangi: 80,47%

c. Daun Sirih: 94,15%

→ Daun sirih tetap tampil unggul dan konsisten. Penurunan pada daun kemangi kembali terjadi, memperkuat indikasi masalah pada generalisasi kelas ini..


Pengujian 10

a. Daun Jambu Biji: 60,20%

b. Daun Kemangi: 91,86%

c. Daun Sirih: 90,08%

→ Di pengujian akhir, akurasi pengenalan daun jambu biji kembali turun drastis, mengindikasikan kelemahan generalisasi yang berulang pada kelas ini. Sementara itu, daun kemangi dan sirih tetap stabil.



Gambar 4.2 Grafik Hasil Uji Daun Herbal

Dari tabel hasil uji dan gambar grafik dari ketiga daun, diperoleh uji pada daun jambu biji dengan nilai tertinggi pada pengujian ke 3 dengan nilai akurasi tertinggi 98,26% dan pengujian ke 5 dengan nilai akurasi terendah 59,27%. Kemudian pada daun kemangi dengan nilai tertinggi pada pengujian ke 2 dengan nilai akurasi

tertinggi 96,60% dan pengujian ke 9 dengan nilai akurasi terendah 80,47%. Kemudian pada daun sirih dengan nilai tertinggi pada pengujian ke 1 dengan nilai akurasi tertinggi 98,56% dan pengujian ke 10 dengan nilai akurasi terendah 86,08%.

BAB V

PENUTUP

5.1. Kesimpulan

Kesimpulan dari Klasifikasi Daun Herbal Berbasis Citra Menggunakan *Convolutional Neural Network (CNN) Dengan Hyperparameter Tuning Random Search* adalah sebagai berikut:

1. Dengan menggunakan bahasa pemrograman python maka dapat membangun Klasifikasi Daun Herbal Berbasis Citra Menggunakan *Convolutional Neural Network (CNN) Dengan Hyperparameter Tuning Random Search*.
2. Pengaruhnya sangat besar terutama ketika menentukan seberapa banyak pola visual (tekstur, tepi, bentuk) yang bisa dikenali model pada tiap layer konvolusi dan begitu juga dengan penentuan kernel.
3. Dengan menggunakan konsep klasifikasi machine learning maka orang-orang dapat mengetahui jenis daun herbal.

5.2. Saran

Saran dari Klasifikasi Daun Herbal Berbasis Citra Menggunakan *Convolutional Neural Network (CNN) Dengan Hyperparameter Tuning Random Search* adalah sebagai berikut:

1. Diharapkan untuk penelitian selanjutnya menggunakan data training yang lebih banyak sehingga dapat meningkatkan akurasi hasil klasifikasi.
2. Sebaiknya menggunakan gambar dengan kualitas tinggi sehingga program yang dibuat dapat mengenalinya dengan baik.

3. Sebaiknya aplikasi dapat dikembangkan menjadi dapat memotret daun lalu melakukan klasifikasi.

DAFTAR PUSTAKA

- Aaisyah Salmaa Putri Atmaja, D., & Kalimantan Timur, U. (2025). Implementation of Grayscale Image Transformation and Histogram Equalization Methods in Digital Image Processing. *Sistem Kendali & Jaringan* E-ISSN, 4, 2808–3520. <https://doi.org/10.58982/krisnadana.v4i2.739>
- Abdul Syawal Laan, M., U Malahina Teknik Informatika Sekolah Tinggi Manajemen Informatika Komputer Uyelindo Kupang Jl Perintis Kemerdekaan I, E. A., Putih, K., Oebobo, K., Kupang, K., & Tenggara Tim, N. (2025). PENERAPAN MACHINE LEARNING MENGGUNAKAN TEACHABLE MACHINE UNTUK MENDETEKSI JENIS TANAH BERBASIS CITRA DIGITAL. In *Jurnal Mahasiswa Teknik Informatika* (Vol. 9, Issue 3).
- Adawiyah Ritonga, & Yahfizham Yahfizham. (2023). Studi Literatur Perbandingan Bahasa Pemrograman C++ dan Bahasa Pemrograman Python pada Algoritma Pemrograman. *Jurnal Teknik Informatika Dan Teknologi Informasi*, 3(3), 56–63. <https://doi.org/10.55606/jutiti.v3i3.2863>
- Agustin, A., Reski, A., Trisazena, A. W., Yuniar, N., Savitri Effendy, D., Lestari, H., Bahar, H., & Prasetya, F. (2024). PEMBUATAN TOGA UNTUK MASYARAKAT DESA PUASANA MAKING TOGA FOR THE PEOPLE OF PUASANA VILLAGE. *Jurnal PEDAMAS (Pengabdian Kepada Masyarakat)*, 2(5).
- Alifian Hernanda Wibowo, K. (n.d.). Indonesian Journal of Mathematics and Natural Sciences Klasifikasi Diabetic Retinopathy Menggunakan CNN dengan Arsitektur yang Dimodifikasi. In *Indones. J. Math. Nat. Sci* (Vol. 46, Issue 1). <http://journal.unnes.ac.id/nju/index.php/JM>

- Auni, A. R., & Sugiharti, E. (2025). Optimization of Mango Plant Leaf Disease Classification Using Concatenation Method of MobileNetV2 and DenseNet201 CNN Architectures. *Scientific Journal of Informatics*, 11(4), 1023–1034. <https://doi.org/10.15294/sji.v11i4.15169>
- Azizah, N., Ardy Nuswantoro, S., Jaya, F., Shofan, R. R., PGRI Situbondo, S., & Timur, J. (n.d.). *ALGORITMA DEEP LEARNING UNTUK PENGENALAN GAMBAR JENIS DAUN Deep Learning Algorithm for Leaf Type Image Recognition*. <http://journal.umpalangkaraya.ac.id/index.php/anterior>
- Devi, P. A. R., & Rosyid, H. (2022). Pemaparan Materi Dasar Pengolahan Citra Digital untuk Upgrade Wawasan Siswa di SMK Dharma Wanita Gresik. *Jurnal Abdi Masyarakat Indonesia*, 2(4), 1259–1264. <https://doi.org/10.54082/jamsi.405>
- Elnursa, D. B., Tahir, M., Jakfar, A. A., & Resnanda, R. M. (2023). Sistem Klasifikasi Citra Simplisia Fructus Dalam Obat Tradisional Madura Menggunakan Transfer Learning Pada Algoritma CNN. *Jurnal Ilmiah Edutic: Pendidikan Dan Informatika*, 10(1), 68–79. <https://doi.org/10.21107/edutic.v10i1.22957>
- Fahmi, A., Hafidz, A., Puspaningrum, E. Y., Lina, A., Informatika, N., Pembangunan, U., Veteran, N., Timur, J., Raya, J., Madya, R., Anyar, G., Surabaya, J., & Timur, I. (2025). PENERAPAN LIGHTGBM MENGGUNAKAN EKSTRAKSI FITUR RUANG WARNA HSV UNTUK KLASIFIKASI REMPAH RIMPANG. In *Jurnal Mahasiswa Teknik Informatika* (Vol. 9, Issue 3).
- Feriska, V., Reni, A., & Dewi, R. (2024). PENILAIAN KESEGARAN IKAN DENGAN METODE K-NEAREST NEIGHBOR DAN PENGOLAHAN CITRA DIGITAL. In *Jurnal Mahasiswa Teknik Informatika* (Vol. 8, Issue 4).

- Joshi, T., Sehgal, H., Puri, S., Karnika, Mahapatra, T., Joshi, M., Deepa, P. R., & Sharma, P. K. (2024). ML-based technologies in sustainable agro-food production and beyond: Tapping the (semi) arid landscape for bioactives-based product development. *Journal of Agriculture and Food Research*, 18. <https://doi.org/10.1016/j.jafr.2024.101350>
- Marpaung, F., Aulia, F., Suryani SKom, N., & Cyra Nabila SKom, R. (n.d.). *COMPUTER VISION DAN PENGOLAHAN CITRA DIGITAL*. www.pustakaaksara.co.id
- Nugroho, E. A., Setiawan, J. D., M, Munadi, & Rustiyanti, A. (2025). Penerapan Teachable Machine Dan Raspberry Pi Pada Sistem Klasifikasi Citra Untuk Inspeksi Cacat Kain. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 12(1), 77–86. <https://doi.org/10.25126/jtiik.2025128932>
- Obuchowicz, R., Strzelecki, M., & Piórkowski, A. (2024). Clinical Applications of Artificial Intelligence in Medical Imaging and Image Processing—A Review. In *Cancers* (Vol. 16, Issue 10). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/cancers16101870>
- Pangaribuan, H., & Sitohang, S. (n.d.). *OPTIMALISASI OBJEK CITRA DENGAN METODE KETETANGGAAN PIKSEL DAN PERERATAAN HISTOGRAM* (Vol. 13, Issue 1).
- Prilianti, K. R., Oktariyanto, V. V., & Setiawan, H. (2024). ORNAMENTAL PLANT IDENTIFICATION SYSTEM USING TRANSFER LEARNING ON CONVOLUTIONAL NEURAL NETWORK. *Jurnal Teknik Informatika (Jutif)*, 5(4), 1015–1023. <https://doi.org/10.52436/1.jutif.2024.5.4.1964>

- Pushpa, B. R., Rani, N. S., Chandrajith, M., Manohar, N., & Nair, S. S. K. (2024). On the importance of integrating convolution features for Indian medicinal plant species classification using hierarchical machine learning approach. *Ecological Informatics*, 81. <https://doi.org/10.1016/j.ecoinf.2024.102611>
- Pushpa Latha, R., & Persis Voola, D. (2025). CLASSIFICATION OF SATELLITE IMAGES USING ADVANCED TOKENS-TO-TOKEN TRANSFORMER WITH PSO OPTIMIZATION. *Journal of Theoretical and Applied Information Technology*, 15(9). www.jatit.org
- Putrama Alkhairi, & Windarto, A. P. (2023). Classification Analysis of Back propagation-Optimized CNN Performance in Image Processing. *Journal of Systems Engineering and Information Technology (JOSEIT)*, 2(1). <https://doi.org/10.29207/joseit.v2i1.5015>
- Raihan, M., Allaam, R., & Wibowo, A. T. (2021). *Klasifikasi Genus Tanaman Anggrek Menggunakan Metode Convolutional Neural Network (CNN)*. 8(2), 1153.
- Ramadhani, F., Rahardiantoro, S., & Masjkur, M. (2024). Acne Severity Classification Study Using Convolutional Neural Network Algorithm with MobileNetV2 Architecture. *Indonesian Journal of Statistics and Its Applications*, 8(2), 112–128. <https://doi.org/10.29244/ijsa.v8i2p112-128>
- Saputra, R., & Ramadhanu, A. (2025). Klasifikasi Citra Buah Jeruk Mandarin, Jeruk Nipis, dan Stroberi Menggunakan Algoritma PCA dan Metode K-Nearest Neighbor (KNN). *JPG: Jurnal Pendidikan Guru Journal*, 6(1), 162–172. <https://ejournal.uika-bogor.ac.id/index.php/jpg/index>
- Sembiring, A. P., Faza, S., Abdi, M., & Tanjung, P. (2021). EXPERIMENTAL ANALYSIS OF HYPERPARAMETERS TUNING ON CLASSIFICATION OF

CRIME NEWS IN INDONESIA. *Journal of Theoretical and Applied Information Technology*, 31, 24. www.jatit.org

Widiputra, H., Adele Mailangkay, & Elliana Gautama. (2021). Prediksi Indeks BEI dengan Ensemble Convolutional Neural Network dan Long Short-Term Memory. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(3), 456–465. <https://doi.org/10.29207/resti.v5i3.3111>

Xu, Z., Yao, Q., Li, Y., & Yang, Q. (n.d.). *Understanding and Simplifying Architecture Search in Spatio-Temporal Graph Neural Networks*. <https://github.com/AutoML-Research/SimpleSTG>.

LAMPIRAN



MAJLIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PIMPINAN PESAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UMSU Terakreditasi A Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 89/SK/BAN-PT/Akred/PT/III/2019
 Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6622400 - 66224567 Fax. (061) 6625474 - 6631003
 Email: info@umsu.ac.id, pps@umsu.ac.id, umsumedan@umsu.ac.id, umsumedan@umsu.ac.id, umsumedan@umsu.ac.id, umsumedan@umsu.ac.id

PENETAPAN DOSEN PEMBIMBING
PROPOSAL/SKRIPSI MAHASISWA
NOMOR : 476/II.3-AU/UMSU-09/F/2025

Assalamu'alaikum Warahmatullahi Wabarakatuh

Dekan Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara, berdasarkan Persetujuan permohonan judul penelitian Proposal / Skripsi dari Ketua / Sekretaris.

Program Studi : Teknologi Informasi
 Pada tanggal : 08 Mei 2025

Dengan ini menetapkan Dosen Pembimbing Proposal / Skripsi Mahasiswa.

Nama : Ichsan Arif
 NPM : 2109020124
 Semester : VIII (Delapan)
 Program studi : Teknologi Informasi
 Judul Proposal / Skripsi : Penerapan Algoritma Random Forest Dalam Klasifikasi Kualitas Udara Di Kawasan Industri Medan

Dosen Pembimbing : Mahardika Prawira Tanjung, S.Kom., M.Kom.

Dengan demikian di izinkan menulis Proposal / Skripsi dengan ketentuan

1. Penulisan berpedoman pada buku panduan penulisan Proposal / Skripsi Fakultas Ilmu Komputer dan Teknologi Informasi UMSU
2. Pelaksanaan Sidang Skripsi harus berjarak 3 bulan setelah dikeluarkannya Surat Penetapan Dosen Pembimbing Skripsi.
3. Proyek Proposal / Skripsi dinyatakan " BATAL " bila tidak selesai sebelum Masa Kadaluaarsa tanggal : 08 Mei 2026
4. Revisi judul.....

Wassalamu'alaikum Warahmatullahi Wabarakatuh.

Ditetapkan di : Medan
 Pada Tanggal : 10 Dzulqa'dah 1446 H
 08 Mei 2025M

Dekan



Cc. File





MAJELIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PIMPINAN PUSAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UMSU Terakreditasi A Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 89/SK/AN-PT/Akred/PT/10/2019
 Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6622400 - 66224567 Fax. (061) 6625474 - 6631003
 Email: info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id

Berita Acara Pembimbingan Proposal

Nama Mahasiswa : Ichsan Arif Program Studi : Teknologi Informasi
 NPM : 2109020124 Konsentrasi :
 Nama Dosen Pembimbing : Mochafika Adi Pratiwi Judul Penelitian : Kriptografi Dasar untuk Keamanan
 S.Kom, M.Kom Data Penggunaan Perangkat Lunak: NetBeans, Java, MySQL, PHP, JavaScript, CSS, HTML, jQuery, Bootstrap, Font-Awesome, Google Fonts, etc.

Tanggal Bimbingan	Hasil Evaluasi	Paraf Dosen
3/may-2025	Revisi Judul	ht
5/may-2025	Acc judul dan revisi bab I, II	ht
8/may-2025	Koreksi Sintaksis Latar belakang	ht
15/may-2025	Koreksi Sintaksis Landasan teori	ht
19/may-2025	Revisi bab III	ht
23/may-2025	ACC Sempurna	ht

Diketahui oleh:
 Ketua Program Studi
 Teknologi Informasi
 (.....)

Medan,.....
 Disetujui oleh:
 Dosen Pembimbing
 (Mochafika Adi Pratiwi)



MAJELIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PIMPINAN PUSAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UMSU Terakreditasi A Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 89/SK/AN-PT/Akred/PT/10/2019
 Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6622400 - 66224567 Fax. (061) 6625474 - 6631003
 Email: info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id, info@umsu.ac.id

Berita Acara Pembimbingan Skripsi

Nama Mahasiswa : Ichsan Arif Program Studi : Teknologi Informasi
 NPM : 2109020124 Konsentrasi :
 Nama Dosen Pembimbing : Mochafika Adi Pratiwi Judul Penelitian : Kriptografi Dasar untuk Keamanan
 S.Kom, M.Kom Data Penggunaan Perangkat Lunak: NetBeans, Java, MySQL, PHP, JavaScript, CSS, HTML, jQuery, Bootstrap, Font-Awesome, Google Fonts, etc.

Item	Hasil Evaluasi	Tanggal	Paraf Dosen
Bab IV	Revisi penulisan code	30/06/2025	ht
Bab IV	Koreksi Hasil perbaikan code	03/07/2025	ht
Bab IV	Penambahan dataset Training & Testing	06/07/2025	ht
Bab IV	Koreksi Hasil uji Dataset	14/07/2025	ht
Bab IV	Revisi Penulisan Hasil uji dataset	24/07/2025	ht
Bab IV	Penambahan Gambar Hasil Prediksi	29/07/2025	ht
Bab IV & V	Koreksi Hasil Bab IV & V kesimpulan dan saran	31/07/2025	ht
	ACC Sidang	02/08/2025	ht

Diketahui oleh:
 Ketua Program Studi
 Teknologi Informasi
 (.....)

Medan,.....
 Disetujui oleh:
 Dosen Pembimbing
 (Mochafika Adi Pratiwi)



ICHSAN ARIF.docx

ORIGINALITY REPORT

29%	27%	10%	16%
SIMILARITY INDEX	INTERNET SOURCES	PUBLICATIONS	STUDENT PAPERS

PRIMARY SOURCES

1	Submitted to Universitas Islam Riau Student Paper	3%
2	repositori.uma.ac.id Internet Source	3%
3	Submitted to Universitas Muhammadiyah Sumatera Utara Student Paper	3%
4	repository.umsu.ac.id Internet Source	1%
5	Alfataniah Nur Fajrina, Zein Hanni Pradana, Sevia Indah Purnama, Shinta Romadhona. "Penerapan Arsitektur EfficientNet-B0 Pada Klasifikasi Leukimia Tipe Acute Lymphoblastik Leukimia", Jurnal Riset Rekayasa Elektro, 2024 Publication	1%
6	jutif.if.unsoed.ac.id Internet Source	1%
7	kc.umn.ac.id Internet Source	1%
8	Submitted to Leaders Institute Student Paper	1%
9	digilib.uinkhas.ac.id Internet Source	<1%
10	journal.aptii.or.id Internet Source	