

DISERTASI

**EGCLAMNETL2: MODEL PENGENALAN CITRA DAUN
FITOMEDISIN MENGGUNAKAN *CONTRAST ENHANCEMENT*
DAN *REGULARIZED DEEP LEARNING* BERBASIS *ENSEMBLE
BOOSTING***

**Diajukan Untuk Memenuhi Salah Satu Syarat Memperoleh Gelar
Doktor Dalam Bidang Ilmu Teknik Informatika**



**VINA AYUMI
03013682126016**

**PROGRAM DOKTOR ILMU TEKNIK
FAKULTAS TEKNIK
UNIVERSITAS SRIWIJAYA
2023**

DISERTASI

**EGCLAMNETL2: MODEL PENGENALAN CITRA DAUN
FITOMEDISIN MENGGUNAKAN *CONTRAST ENHANCEMENT*
DAN *REGULARIZED DEEP LEARNING* BERBASIS *ENSEMBLE
BOOSTING***

**Diajukan Untuk Memenuhi Salah Satu Syarat Memperoleh Gelar
Doktor Dalam Bidang Ilmu Teknik Informatika**



**VINA AYUMI
03013682126016**

**PROGRAM DOKTOR ILMU TEKNIK
FAKULTAS TEKNIK
UNIVERSITAS SRIWIJAYA
2023**

HALAMAN PENGESAHAN

**EGCLAMNETL2: MODEL PENGENALAN CITRA DAUN FITOMEDISIN
MENGUNAKAN *CONTRAST ENHANCEMENT* DAN *REGULARIZED DEEP
LEARNING* BERBASIS *ENSEMBLE BOOSTING***

DISERTASI

Diajukan Untuk Melengkapi Salah Satu Syarat
Memperoleh Gelar Doktor Dalam Bidang Ilmu Teknik Informatika

Oleh
Vina Ayumi
03013682126016

Palembang, 09 November 2023

Promotor



Dr. Ermatita, M. Kom
NIP. 196709132006041001

Ko-Promotor



Dr. Abdiansah, S.Kom., M.CS.
NIP.198410012009121005

Mengetahui

Dekan Fakultas Teknik,



Prof. Dr. Ir. H. Joni Arliansyah, M.T.
NIP.-196706151995121002

Koordinator Program Studi,



Prof. Dr. Ir. Nukman, M.T.
NIP. 195903211987031001

HALAMAN PERSETUJUAN

Karya tulis ilmiah berupa Disertasi ini dengan judul "*EGCLAMNETL2: Model Pengenalan Citra Daun Fitomedisin Menggunakan Contrast Enhancement Dan Regularized Deep Learning Berbasis Ensemble Boosting*" telah dipertahankan dihadapan Tim Penguji Karya Tulis Ilmiah Program Studi Doktor Ilmu Teknik, Fakultas Teknik, Universitas Sriwijaya pada tanggal 02 November 2023.

Palembang, 09 November 2023

Tim Penguji Karya Tulis Ilmiah Berupa Disertasi

Ketua:

Prof. Dr. Ir. Nukman, M.T
NIP. 195903211987031001

()

Anggota:

1. Dr. Mujiono Sadikin, MT.
NIDN. 0406127002
2. Prof. Dr. Yusuf Hartono, M.Sc.
NIP. 196411161990031002
3. Dr. Ali Ibrahim, M.T.
NIP. 198407212019031004

()

()


()

Mengetahui

Dekan Fakultas Teknik,

Koordinator Program Studi,


Prof. Dr. Ir. H. Jom Arliansyah, M.T.
NIP. 196706151995121002


Prof. Dr. Ir. Nukman, M.T.
NIP. 195903211987031001

ABSTRAK

EGCLAMNETL2: MODEL PENGENALAN CITRA DAUN FITOMEDISIN MENGGUNAKAN *CONTRAST ENHANCEMENT* DAN *REGULARIZED DEEP LEARNING* BERBASIS *ENSEMBLE BOOSTING*

Pengetahuan fitomedisin adalah pengetahuan yang berhubungan dengan penggunaan tanaman untuk pengobatan yang diturunkan secara turun temurun. Studi tentang fitomedisin tidak hanya berkaitan dengan manajemen pengetahuan tetapi juga pemrosesan gambar. Untuk mengelola pengetahuan ini, perlu adanya implementasi teknologi computer vision untuk memproses data gambar tanaman fitomedisin agar dapat dikelola dengan mudah. Dalam penelitian ini dilakukan eksperimen dengan menggunakan empat model yang berbeda yaitu MNET, MNETL2, GCLAMNET dan EGCLAMNETL2. Eksperimen MNET yang dilakukan menggunakan pengaturan parameter yang ada dengan *value* antara lain, nilai *batch size*: 32, nilai *epoch* 50, nilai *optimizer*: Adam nilai *learning rate* 0.0001 dan nilai *input shape* 224x224. Regularisasi L2 (0.05) pada model MNETL2 berdampak signifikan pada nilai *loss*. Nilai *loss* pada model MNETL2 cenderung menurun dibandingkan MNET secara signifikan pada setiap *epoch*. Ada tiga parameter yang perlu diinisiasi pada model GCLA yang diusulkan yaitu: *clipLimit*, *tileGridSize* dan *midGamma*. Parameter *clipLimit* mengatur nilai *contrast limiting threshold*. Parameter *clipLimit* didefinisikan dengan nilai (3.0). Parameter *tileGridSize* digunakan untuk jumlah *tile* di setiap baris dan kolom piksel citra fitomedisin. Parameter *tileGridSize* didefinisikan dengan nilai (8,8) sedangkan parameter *midGamma* didefinisikan dengan nilai (1.0). Beberapa eksperimen sebelumnya dilakukan untuk mengetahui koefisien parameter yang sesuai untuk masing-masing model sebelum digunakan pada EGCLAMNETL2. Arsitektur model EGCLAMNETL2 yang diusulkan sebagai model pengenalan citra daun tanaman fitomedisin menggunakan pendekatan *ensemble boosting*. Berdasarkan hasil eksperimen EGCLAMNETL2 mendapatkan akurasi pengujian paling baik dibandingkan model sebelumnya yaitu 90,72%, MNET mendapatkan akurasi sebesar 83,73%, GCLAMNET mendapatkan akurasi sebesar 69,39% dan MN mendapatkan akurasi sebesar 84,27%.

Kata Kunci : *phytomedicine, deep learning, image processing, contrast enhancement, regularization, ensemble boosting*

ABSTRACT

EGCLAMNETL2: PHYTOMEDISIN LEAF IMAGE RECOGNITION MODEL USING CONTRAST ENHANCEMENT AND REGULARIZED DEEP LEARNING BASED ON ENSEMBLE BOOSTING

Phytomedicine knowledge is knowledge related to the use of plants for treatment that are passed down from generation to generation. The study of phytomedicine is concerned not only with knowledge management but also image processing. To manage this knowledge, it is necessary to implement computer vision technology to process phytomedicine plant image data so that it can be managed easily. This study conducted experiments using four different models, namely MNET, MNETL2, GCLAMNET and EGCLAMNETL2. MNET experiments conducted using existing parameter settings with values include batch size: 32, epoch: 50, optimizer value: Adam, learning rate value = 0.0001 and input shape value: 224x224. L2 regularization (0.05) in the MNETL2 model has a significant impact on loss values. The loss value in the MNETL2 model tends to decrease compared to MNET significantly at each epoch. There are three parameters that need to be initialized in the proposed GCLA model: clipLimit, tileGridSize and midGamma. The clipLimit parameter sets the contrast limiting threshold value. The clipLimit parameter is defined with a value of (3.0). The tileGridSize parameter is used for the number of tiles in each row and column of phytomedicine image pixels. The tileGridSize parameter is defined with a value (8.8) while the midGamma parameter is defined with a value (1.0). Several previous experiments were conducted to determine the appropriate parameter coefficients for each model before being used on EGCLAMNETL2. The proposed EGCLAMNETL2 model architecture as a model of phytomedicine plant leaf image recognition uses an ensemble boosting approach. Based on the experimental results, EGCLAMNETL2 got the best test accuracy compared to the previous model, which was 90.72%, MNET got an accuracy of 83.73%, GCLAMNET got an accuracy of 69.39% and MNETL2 got an accuracy of 84.27%.

Keywords : *phytomedicine, deep learning, image processing, contrast enhancement, regularization, ensemble boosting*

KATA PENGANTAR

Alhamdulillah, puji syukur penulis ucapkan kepada Allah SWT karena atas rahmat dan karunia-Nya kami dapat menyelesaikan Proposal Disertasi Doktor Ilmu Teknik (Teknik Informatika) berjudul “*EGCLAMNETL2: Model Pengenalan Citra Daun Fitomedisin Menggunakan Contrast Enhancement dan Regularized Deep Learning Berbasis Ensemble Boosting*”. Penulis mengucapkan terima kasih kepada:

1. Kedua orang tua dan mertua tercinta.
2. Suami, anak dan keluarga besar yang telah mendukung sepenuhnya.
3. Prof. Dr. Taufiq Marwa, SE. M.Si selaku Rektor Universitas Sriwijaya.
4. Prof. Dr. Ir. H. Joni Arliansyah, M.T. selaku Dekan Fakultas Teknik, Universitas Sriwijaya.
5. Dr. Bhakti Yudho Suprpto, S.T., M.T. selaku Wakil Dekan Bidang Akademik, Universitas Sriwijaya.
6. Prof. Dr. Ir. Nukman, M.T., selaku Koordinator Program Studi Doktor Ilmu Teknik, Fakultas Teknik, Universitas Sriwijaya.
7. Dr. Ermatita, M. Kom., selaku Promotor yang telah memberikan bimbingan dan arahan dalam penyelesaian disertasi ini.
8. Dr. Abdiansah, S. Kom., M.CS., selaku Ko-Promotor yang telah memberikan arahan dalam penyelesaian disertasi ini.
9. Prof. Dr. Ir. Nukman, M.T., Dr. Mujiono Sadikin, MT., Prof. Dr. Yusuf Hartono, M.Sc, dan Dr. Ali Ibrahim, M.T. selaku Tim Penguji yang telah memberikan saran untuk peningkatan kualitas disertasi ini.

Selain itu, penulis mengucapkan terima kasih kepada semua pihak yang terlibat lainnya yang telah memberikan dukungan, semangat dan bantuan dalam pelaksanaan penelitian ini.

Jakarta, Juli 2023



Vina Ayumi

DAFTAR ISI

HALAMAN PENGESAHAN	ii
ABSTRAK.....	iv
ABSTRACT	v
KATA PENGANTAR	vi
DAFTAR ISI	vii
DAFTAR GAMBAR	ix
DAFTAR TABEL.....	xi
BAB 1 PENDAHULUAN	1
1.1. Latar Belakang.....	1
1.2. Rumusan Masalah	8
1.3. Tujuan Penelitian	8
1.4. Manfaat Penelitian.....	9
1.5. Batasan Penelitian	10
1.6. Sistematika Penulisan.....	11
BAB 2 TINJAUAN PUSTAKA	12
2.1. Citra Digital	12
2.2. Tanaman Fitomedisin	12
2.3. Augmentasi Data	14
2.3.1. Random Contrast	14
2.3.2. Rotation Range	15
2.3.3. Horizontal Flip.....	15
2.3.4. Vertical Flip.....	16
2.3.5. Brightness Range.....	17
2.3.6. Channel Shift Range.....	17
2.4. Contrast Enhancement.....	18
2.4.1. CLAHE.....	19
2.4.2. Gamma Correction	22
2.5. Deep Learning	24
2.5.1. MNET.....	24
2.5.2. Regularisasi L2	29
2.5.3. Ensemble Boosting.....	33
2.6. Pengembangan Aplikasi	34
2.6.1. Feature Modelling	35
2.6.2. Unified Modelling Language	36
2.7. Metode Evaluasi	39
2.8. Penelitian Terkait.....	40
BAB 3 METODOLOGI PENELITIAN	44
3.1. Tahapan Penelitian	44
3.2. Studi Literatur.....	45

3.3.	Pengumpulan Data.....	46
3.4.	Persiapan Dataset Penelitian.....	49
3.5.	Pengembangan EGCLAMNETL2.....	50
3.6.	Pengembangan Prototipe Aplikasi	51
3.7.	Penulisan Disertasi dan Publikasi.....	52
BAB 4 PENGEMBANGAN MODEL DEEP LEARNING		54
4.1.	Persiapan Dataset Penelitian.....	54
4.1.1.	Random Contrast	54
4.1.2.	Rotation Range	56
4.1.3.	Horizontal Flip.....	58
4.1.4.	Vertical Flip.....	60
4.1.5.	Brightness Range.....	61
4.1.6.	Channel Shift Range.....	63
4.2.	Pengembangan Model EGCLAMNETL2	65
4.2.1.	Eksperimen MNET.....	65
4.2.2.	Eksperimen MNETL2	71
4.2.3.	Eksperimen GCLAMNET	77
4.2.4.	Eksperimen EGCLAMNETL2.....	83
BAB 5 PENGEMBANGAN PROTOTIPE APLIKASI.....		87
5.1.	Use Case Diagram	87
5.2.	Class Diagram	88
5.3.	Feature Modelling	90
5.4.	Interface Design.....	91
BAB 6 KESIMPULAN DAN SARAN		95
6.1.	Kesimpulan	95
6.2.	Saran	96
DAFTAR PUSTAKA		97
LAMPIRAN		103
	Lampiran 1 – Daftar Luaran atau Publikasi	104
	Lampiran 2 - Artikel Konferensi Terindeks Scopus.....	105
	Lampiran 3 - Artikel Jurnal Terindeks Scopus Q3.....	112
	Lampiran 4 - Artikel Jurnal Terindeks Scopus Q3.....	119
	Lampiran 5 - Buku ISSN.....	138
	Lampiran 6 - Surat Keterangan Penelitian	142
	Lampiran 7 - Transcribe Wawancara	146
	Lampiran 8 - Kode Pemrograman	149

DAFTAR GAMBAR

Gambar 2.1 Aplikasi MobileNets	25
Gambar 2.2 Depthwise Separable Convolution pada MNET	26
Gambar 2.3 Urutan <i>depthwise separable convolutions</i> pada MNET	27
Gambar 2.4 Residual Connection pada MNET versi 2.....	28
Gambar 2.5 Arsitektur pada MNET versi 2.....	28
Gambar 2.6 Ilustrasi cara kerja pada MNET versi 2.....	29
Gambar 2.7 Kondisi <i>high variance</i> pada pemodelan data	30
Gambar 2.8 Kondisi <i>good fit</i> pada pemodelan data	31
Gambar 2.9 Berbagai kondisi pada pemodelan data.....	32
Gambar 2.10 Konsep <i>Ensemble Boosting</i>	34
Gambar 2.11 Piramida Analisis Kebutuhan.....	35
Gambar 2.12 Contoh Feature Modelling	36
Gambar 2.13 Klasifikasi Diagram di UML	37
Gambar 2.14 Contoh Use Case Diagram	38
Gambar 2.15 Contoh Class Diagram	38
Gambar 3.1 Tahapan Penelitian	45
Gambar 3.2 Persentase Dataset.....	49
Gambar 3.3 Model EGCLAMNETL2 berbasis <i>ensemble boosting</i>	51
Gambar 3.4 Struktur Pemodelan Fitomedisin-ID	52
Gambar 4.1 Pseudocode <i>Random Contrast Augmentation</i>	55
Gambar 4.2 Citra Hasil Teknik <i>Random Contrast Augmentation</i>	56
Gambar 4.3 Pseudocode <i>Rotation Range Augmentation</i>	57
Gambar 4.4 Citra Hasil Teknik <i>Rotation Range Augmentation</i>	58
Gambar 4.5 Pseudocode <i>Horizontal Flip Augmentation</i>	59
Gambar 4.6 Citra Hasil Teknik <i>Horizontal Flip Augmentation</i>	59
Gambar 4.7 Pseudocode <i>Vertical Flip Augmentation</i>	60
Gambar 4.8 Citra Hasil Teknik <i>Vertical Flip Augmentation</i>	61
Gambar 4.9 Pseudocode <i>Vertical Flip Augmentation</i>	62
Gambar 4.10 Citra Hasil Teknik <i>Brightness Range Augmentation</i>	63
Gambar 4.11 Channel Shift Range <i>Flip Augmentation</i>	64
Gambar 4.12 Citra Hasil Teknik <i>Random Contrast Augmentation</i>	65
Gambar 4.13 Pseudocode <i>MNET</i>	66
Gambar 4.14 Arsitektur <i>MNET</i>	66
Gambar 4.15 Hasil Eksperimen MNET	67
Gambar 4.16 Parameter MNET	67
Gambar 4.17 Confusion Matrix MNET (Pengujian)	68
Gambar 4.18 Grafik Accuracy dan Loss pada Model MNET	70
Gambar 4.19 Pseudocode <i>MNETL</i>	71

Gambar 4.20 Model MNETL2.....	73
Gambar 4.21 Hasil Eksperimen MNETL2	74
Gambar 4.22 Hasil Confusion Matrix MNETL2	74
Gambar 4.23 Perbandingan Grafik Accuracy Model (a) MNET dan (b) MNETL2.....	76
Gambar 4.24 Perbandingan Grafik Loss Antara Model (a) MNET dan (b) MNETL2	77
Gambar 4.25 Pseudocode GCLAMNET	77
Gambar 4.26 Arsitektur GCLAMNET	78
Gambar 4.27 Hasil Eksperimen GCLAMNET	79
Gambar 4.28 Confusion matrix dari model GCLAMNET	80
Gambar 4.29 Grafik <i>Accuracy</i> dan <i>Loss</i> pada Model GCLAMNET	82
Gambar 4.30 Pencahayan Pada Citra Daun Jintan.....	83
Gambar 4.31 Hasil <i>Contrast Enhancement</i>	84
Gambar 4.32 Perbandingan Hasil Eksperimen	86
Gambar 5.1 <i>Use Case Diagram</i> Fitomedisin-ID	88
Gambar 5.2 <i>Class Diagram</i> FitomedisinID	89
Gambar 5.3 <i>Feature Modelling</i> dari Aplikasi <i>Fitomedisin</i>	90
Gambar 5.4 Perancangan <i>Header</i> Halaman Beranda.....	91
Gambar 5.5 Perancangan <i>Body</i> Halaman Beranda	92
Gambar 5.6 Perancangan <i>Footer</i> Halaman Beranda.....	92
Gambar 5.7 Perancangan Antarmuka Halaman Beranda Fitomedisin-ID	93
Gambar 5.8 Perancangan Antarmuka Detail Tanaman Fitomedisin.....	94

DAFTAR TABEL

Tabel 2.1 Model Confusion Matrix	39
Tabel 2.2 Penelitian Terkait Pengenalan Citra Daun Tanaman Fitomedisin.....	40
Tabel 3.1 Dataset Penelitian	47
Tabel 3.2 Jumlah Dataset Penelitian.....	50
Tabel 3.3 Skenario Eksperimen	50
Tabel 3.4 Luaran Penelitian	52
Tabel 4.1 Jumlah Data Hasil Teknik <i>Random Contrast Augmentation</i>	55
Tabel 4.2 Jumlah Data Hasil Teknik <i>Rotation Range Augmentation</i>	57
Tabel 4.3 Jumlah Data Hasil Teknik <i>Horizontal Flip Augmentation</i>	59
Tabel 4.4 Jumlah Data Hasil Teknik <i>Vertical Flip Augmentation</i>	61
Tabel 4.5 Jumlah Data Hasil Teknik <i>Brightness Range Augmentation</i>	63
Tabel 4.6 Jumlah Data Hasil Teknik <i>Channel Shift Range Augmentation</i>	64
Tabel 4.7 Hasil Prediksi Model MNET	69
Tabel 4.8 Hasil Prediksi Model MNETL2.....	75
Tabel 4.9 Hasil Prediksi Model GCLAMNET	80
Tabel 4.10 Perbandingan Akurasi MNET dan GCLAMNET (Per Kelas)	82
Tabel 4.11 Hasil Prediksi Model EGCLAMNETL2	84
Tabel 4.12 Perbandingan Akurasi EGCLAMNETL2.....	85

BAB 1 PENDAHULUAN

Pada bab ini secara khusus dijelaskan mengenai latar belakang dan kontribusi penelitian. Pendahuluan berisi tentang latar belakang serta justifikasi topik pembahasan layak untuk dijadikan sebagai topik penelitian. Isi dari bab pendahuluan ini antara lain adalah latar belakang, rumusan masalah, batasan masalah, tujuan dan manfaat, metodologi serta sistematika penulisan.

1.1. Latar Belakang

Tanaman fitomedisin digunakan untuk pengobatan yang diturunkan secara turun-temurun oleh masyarakat di Indonesia. Tanaman fitomedisin dinilai memiliki kelebihan dalam hal keamanan, kemudahan akses untuk mendapatkannya, biaya rendah dan kesesuaian dengan tradisi budaya (Barbosa et al., 2012). Tanaman fitomedisin mengandung zat atau bahan aktif yang berguna untuk memelihara kesehatan tubuh atau penyembuhan penyakit (Maulidiya & Kasrina, 2016). Potensi tumbuhan fitomedisin di Indonesia ini apabila dikelola dengan baik akan sangat bermanfaat dari segi ekonomi, sosial budaya maupun lingkungan.

Beberapa penelitian menunjukkan bahwa masyarakat adat cenderung menggunakan tanaman fitomedisin untuk pengobatan alternatif (Maulidiya & Kasrina, 2016). Berdasarkan Data Riset Kesehatan Dasar (Riskesdas) dari Badan Penelitian dan Pengembangan Kesehatan, Kementerian Kesehatan menunjukkan bahwa 30,4% rumah tangga di Indonesia memanfaatkan pelayanan kesehatan tradisional, diantaranya 77,8% rumah tangga memanfaatkan jenis pelayanan kesehatan tradisional keterampilan tanpa alat, dan 49,0% rumah tangga memanfaatkan ramuan. Menurut hasil penelitian, dari sekian banyak jenis tanaman fitomedisin sebanyak 20-22% yang dibudidayakan, sedangkan sekitar 78% diperoleh melalui pengambilan langsung (eksplorasi) dari hutan (Balitkes, 2013) .

Pemerintah telah mengupayakan dokumentasi pembuatan Bank Data Obat Bahan Alam Indonesia yang dibuat dan dikelola oleh Badan Pengawas Obat dan Makanan. Informasi yang tersedia meliputi agenda kerjasama Badan POM dengan berbagai institusi dan perguruan tinggi terkait penelitian tanaman fitomedisin, hayati bahan

fitomedisin, publikasi artikel ilmiah, dan taksonomi tanaman fitomedisin. Hal serupa juga dilakukan oleh Balai Jaringan Informasi Ilmu Pengetahuan dan Teknologi (Balai IPTEKnet) BPPT melalui websitenya yang membuat pangkalan data berisi daftar tanaman fitomedisin Indonesia. Selain itu, pangkalan data tersebut menggunakan indeks nama tanaman dan nama penyakit sebagai kata kunci pencarian dan pelacakan data. Data yang tersedia merupakan hasil kerjasama IPTEKnet dengan CODATA ICSU Indonesia (Maulidiya & Kasrina, 2016).

Penelitian di bidang tanaman fitomedisin juga semakin gencar dilakukan. Berbagai informasi terkait karakteristik, fitokimia, dan pemanfaatan tanaman obat tersebut perlu terus dipublikasikan kepada masyarakat. Salah satu cara pengelolaan informasi tanaman fitomedisin yaitu melalui sebuah aplikasi yang dilengkapi fitur pengenalan tanaman fitomedisin yang dapat diakses melalui internet. Implementasi teknologi *computer vision* dapat digunakan untuk mempermudah mengenali tanaman fitomedisin agar tidak ada kesalahan dalam penggunaannya untuk pengobatan (Dahigaonkar & Kalyane, 2018; Nithiyanandhan & Reddy, 2017).

Proses identifikasi tumbuhan obat dilakukan masyarakat dengan berbagai cara, diantaranya melalui taksonomi, seperti bunga, biji, daun, akar dan lain-lain. Namun, daun merupakan salah satu bagian tanaman yang sering digunakan untuk mengenali jenis tanaman. Selain itu, salah satu bagian tanaman fitomedisin yang paling banyak digunakan untuk pengobatan adalah bagian daun. Daun juga digunakan untuk mengenali dan mengklasifikasi tanaman, karena setiap jenis tanaman memiliki beberapa fitur yaitu bentuk, warna dan tekstur yang berbeda. Selain itu, daun lebih mudah diperoleh karena tidak tergantung pada musim (Riska, Cahyani, & Rosadi, 2015).

Daun tanaman fitomedisin biasanya dikenali berdasarkan ciri fisik dan warna pada daun. Untuk mengenali atau mengidentifikasi daun cara yang paling sederhana adalah dengan melihat bentuk, warna dan tekstur daunnya, akan tetapi tidak banyak orang yang dapat membedakan antara daun yang satu dengan yang lain. Beragamnya jenis tumbuhan fitomedisin sehingga kemampuan untuk mengidentifikasi daun tumbuhan fitomedisin dengan tepat menjadi kebutuhan penting bagi pakar maupun masyarakat yang berhubungan dengan penggunaan tumbuhan fitomedisin. Selain itu,

pengenalan biasanya dilakukan dengan memperhatikan daun secara manual dengan membandingkan satu persatu bagian dari tanaman obat. Namun, jika pengenalan atau klasifikasi tersebut dilakukan langsung secara manual memerlukan waktu yang lama (Trinugi Wira Harjanti & Himawan, 2021).

Oleh karena itu dibutuhkan teknologi berbasis komputer sebagai alat bantu untuk mempercepat proses identifikasi daun tanaman fitomedisin (Jamaliah, Whidhiasih, & Maimunah, 2017). Selain itu, sistem teknologi berbasis komputer ini daun tanaman obat ini bermanfaat untuk membantu penderita buta warna dan lansia mengenali daun tanaman fitomedisin agar tidak salah membedakan warna dan mengetahui jenis tanaman yang digunakan (Syam, Rifka, & Aulia, 2021). Teknologi berbasis komputer yang dapat digunakan untuk mengenali daun tanaman fitomedisin yaitu teknologi pengolahan citra digital. Pengolahan citra digital adalah salah satu teknologi yang dikembangkan untuk mendapatkan informasi dari citra dengan cara memodifikasi bagian dari citra yang diperlukan sehingga menghasilkan citra lain yang lebih informatif (Jamaliah et al., 2017).

Pengolahan citra digital merupakan bidang yang mempelajari bagaimana suatu citra dibentuk, dikelola, dan dianalisa untuk mendapatkan informasi yang bermanfaat. Melalui pengolahan citra dapat menghasilkan informasi yang kemudian dapat berguna dalam membantu pekerjaan manusia. Untuk mengenali suatu objek daun secara tepat dibutuhkan citra yang fokus pada objek dengan kontras yang baik agar dapat diidentifikasi dengan cara melakukan *contrast enhancement (CE)* pada citra (Nurnaningsih, Alamsyah, Herdiansah, & Sinlae, 2021).

Studi mengenai *contrast enhancement (CE)* untuk citra daun telah dilakukan oleh penelitian sebelumnya dengan menggunakan beberapa teknik atau metode yang berbeda-beda. Berdasarkan hasil studi literatur pada tahun 2018 hingga 2022, ada beberapa metode yang digunakan untuk melakukan *contrast enhancement (CE)* pada citra daun fitomedisin, antara lain *histogram equalizer (HE)*, *contrast-limited adaptive histogram equalization (CLAHE)* dan *contrast stretching (CS)*.

Penelitian oleh Thanikkal et al. (2018) menggunakan pendekatan *contrast stretching (CS)* untuk memperbaiki citra daun pada dataset citra daun yang memiliki kontras rendah yang dikarenakan hasil pencahayaan yang rendah, kurangnya rentang

dinamis dalam sensor pencitraan, pengaturan lensa yang salah selama akuisisi gambar dan lainnya. Metode lain dari penyempurnaan kontras adalah *histogram equalizer (HE)*. Kedua metode digunakan untuk meningkatkan kontras, lebih tepatnya, menyesuaikan intensitas gambar untuk meningkatkan kontras, namun pada metode *histogram equalization*, bentuk keseluruhan histogram berubah, sedangkan *contrast stretching* bentuk keseluruhan histogram tetap sama (Thanikkal, Dubey, & Thomas, 2018).

Penelitian oleh Singh et al. (2019) menggunakan metode *histogram equalizer (HE)* untuk meningkatkan kualitas citra daun mangga. Dataset penelitian ini terdiri dari 1070 citra daun mangga dengan ukuran 128×128 piksel. Kontras citra ditingkatkan dengan menetapkan nilai intensitas yang seragam ke piksel berdasarkan nilai histogram citra yang ada dengan bantuan fungsi pada metode *histogram equalizer (HE)*. Metode tersebut digunakan untuk meningkatkan citra daun mangga, tetapi kebanyakan kasus menghasilkan pencahayaan dan intensitas saturasi berlebih yang tidak dibatasi pada *histogram equalizer (HE)*. Sebagai saran penelitian lebih lanjut, pengembangan dari metode *HE* yaitu *contrast-limited adaptive histogram equalization (CLAHE)* dapat digunakan untuk eksperimen perbandingan untuk mengetahui apakah dapat memperbaiki masalah dari hasil metode *histogram equalizer* (Singh, Chouhan, Jain, & Jain, 2019).

Penelitian oleh Ansari et al. (2022) menggunakan 400 citra daun sebagai dataset penelitian. Metode yang digunakan adalah *contrast-limited adaptive histogram equalization (CLAHE)* yang digunakan untuk memperbaiki kontras pada citra daun yang ada pada dataset. Histogram nilai piksel dan nilai daerah di sekitarnya dapat diproduksi dengan bantuan *CLAHE* Fungsi *contrast-limited adaptive (CLA)* akan membatasi penyesuaian kontras maksimum pada histogram lokal (Ansari et al., 2022).

Penelitian Chethan et al. (2021) menggunakan metode *contrast-limited adaptive histogram equalization (CLAHE)*. Metode *CLAHE* merupakan peningkatan *adaptive histogram equalization (AHE)* dimana amplifikasi kontras terbatas pada citra daun, sehingga masalah *noise* dapat dikurangi. Identifikasi citra daun tanaman fitomedisin dilakukan dengan menggunakan *support vector machine (SVM)* and *convolutional neural networks (CNN)* sebagai *classifier*. Berdasarkan hasil eksperimen *contrast-limited*

adaptive histogram equalization (CLAHE) memberikan peningkatan citra daun kecerahan dengan kontras yang baik untuk citra daun (Chethan, Donepudi, Supreeth, & Maani, 2021).

Berdasarkan penelitian sebelumnya, metode *CLAHE* merupakan metode dengan kinerja yang baik untuk memperbaiki kontras data citra daun yang rendah dikarenakan kondisi pencahayaan yang rendah, kondisi rentang dinamis dalam sensor pencitraan yang rendah, kondisi pengaturan *aperture* lensa yang salah pada saat pengambilan gambar atau citra. Meskipun *CLAHE* dapat meningkatkan kontras, namun perlu adanya metode lain yang digunakan untuk mengatasi kelebihan kecerahan dan kontras tidak sempurna yang oleh *CLAHE*, terutama pada citra daun yang sebelumnya telah memiliki kontras yang baik tanpa implementasi *CLAHE*. Berdasarkan penelitian oleh Rahman et al (2016), *gamma correction (GC)* dapat menjadi alternatif untuk mengatasi permasalahan yang terjadi dari hasil implementasi *CLAHE* pada citra (Rahman, Rahman, Abdullah-Al-Wadud, Al-Quaderi, & Shoyaib, 2016)

Setelah mengetahui metode *contrast enhancement* yang sesuai dengan permasalahan yang ada, tahap berikutnya menganalisis metode *deep learning* untuk pengenalan citra daun tanaman fitomedisin. Berdasarkan penelitian Anubha et al. (2019) diketahui bahwa pengenalan tanaman fitomedisin dapat menggunakan metode *machine learning* dan *deep learning*. Namun, berdasarkan hasil penelitian menunjukkan bahwa arsitektur *deep learning* mendapatkan hasil yang lebih baik jika dibandingkan dengan metode *machine learning* lainnya dalam pengenalan tanaman fitomedisin (Anubha, Sathiesh Kumar, & Harini, 2019).

Penelitian oleh Azeez & Rajapakse (2019) melakukan pengenalan citra daun tanaman fitomedisin dengan menggunakan algoritma *ResNet*. Dataset yang digunakan berjumlah 552 citra tanaman fitomedisin dengan 7 kelas. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 95.5% (Azeez & Rajapakse, 2019). Penelitian Dileep & Pournami (2019) melakukan pengenalan citra daun tanaman fitomedisin dengan menggunakan algoritma *convolutional neural network (CNN)*. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 95.06%. Algoritma *CNN* merupakan algoritma dengan waktu komputasi yang cukup tinggi sedangkan pengenalan citra daun tanaman fitomedisin memerlukan waktu yang seefisien mungkin (Dileep & Pournami, 2019).

Selanjutnya, Ahila Priyadharshini et al. (2020) melakukan identifikasi citra daun tanaman fitomedisin dengan menggunakan algoritma CNN. Dataset yang digunakan berjumlah 50 kelas tanaman fitomedisin. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 87.25%. Namun, CNN merupakan algoritma dengan waktu komputasi yang cukup tinggi, sedangkan pengenalan citra daun tanaman fitomedisin memerlukan waktu yang cepat karena akan digunakan masyarakat secara langsung (Ahila Priyadharshini, Arivazhagan, & Arun, 2020).

Selanjutnya, Quoc & Hoang (2020) melakukan klasifikasi citra daun tanaman fitomedisin dengan menggunakan algoritma *Xception*. Dataset yang digunakan berjumlah 200 citra tanaman fitomedisin. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 88.26%. Identifikasi citra daun dilakukan dengan menggunakan *Xception* sebagai klasifier dan mendapatkan akurasi 88.26%. Namun, hasil akurasi ini tidak lebih baik dari model algoritma lain padahal citra yang digunakan hanya 200 data (Quoc & Hoang, 2020). Harjanti et al. (2020) melakukan pengenalan citra daun tanaman fitomedisin dengan menggunakan algoritma *neural network (NN)*. Dataset yang digunakan berjumlah 510 citra tanaman fitomedisin. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 84.31%. Model *neural network* merupakan algoritma dengan waktu komputasi yang cukup tinggi, sedangkan pengenalan citra daun tanaman fitomedisin hanya memiliki sumber daya komputasi yang terbatas (T Wira Harjanti, Madenda, Harlan, & Lussiana, 2020).

Selanjutnya, Akter & Hosen (2020) melakukan pengenalan citra daun tanaman fitomedisin dengan menggunakan algoritma *convolutional neural network (CNN)*. Dataset yang digunakan berjumlah 34.123 citra gambar fitomedisin. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 71,3% (Akter & Hosen, 2020). Haryono et al. (2020) melakukan pengenalan citra daun tanaman fitomedisin dengan menggunakan algoritma *convolutional neural network (CNN)*. Dataset yang digunakan berjumlah 4.050 citra gambar dengan 9 kelas. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 94.45%. Namun, model CNN merupakan algoritma dengan waktu komputasi yang cukup tinggi, sedangkan pengenalan citra daun tanaman fitomedisin diperlukan waktu komputasi yang lebih cepat (Haryono, Anam, & Saleh, 2020).

Dat *et al.* (2021) melakukan pengenalan citra daun tanaman fitomedisin dengan menggunakan algoritma *MobileNet (MNET)*. Dataset yang digunakan adalah *Vietnamese Herb Leaf Image (V – Herb) Dataset* yang terdiri dari kelas 29 spesies tanaman fitomedisin yang ada Vietnam. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 97.73%. Identifikasi citra daun tanaman fitomedisin dilakukan dengan menggunakan *MNET* sebagai klasifier dan mendapatkan akurasi 97.73%. Namun, dataset citra eksperimen diambil dari ruangan dengan pencahayaan yang stabil. Penelitian selanjutnya dapat mempertimbangkan, dataset citra yang memiliki hasil kualitas citra yang beragam (Dat, Vu, Truong, Sang, & Bao, 2021).

Berdasarkan penelitian sebelumnya, algoritma *MobileNet (MNET)* merupakan metode dengan kinerja yang baik untuk pengenalan citra daun tanaman fitomedisin. Berdasarkan hasil penelitian, nilai akurasi *MobileNet* mencapai 97.73% (Dat *et al.*, 2021). Selain itu, model *MobileNet (MNET)* memiliki kelebihan karena dapat digunakan sumber daya komputasi yang terbatas untuk melatih seluruh model dengan cara mengatur *fine-tuning* pada model ResNet (Jafar & Lee, 2021; Zahisham, Lee, & Lim, 2020).

Namun, pada model *MobileNet (MNET)* tersebut rentan terhadap *overfitting* karena banyaknya parameter dan sedikitnya jumlah data latih yang digunakan untuk melatih model. Akibatnya, model dapat bekerja dengan baik pada sampel pelatihan, tetapi hasilnya pada sampel validasi atau pengujian buruk (Rice, Wong, & Kolter, 2020). Oleh karena itu, model tidak dapat digeneralisasi untuk sampel data baru. Biasanya, teknik seperti augmentasi data, *dropout*, dan regularisasi *L2*, digunakan untuk mengurangi dampak dari masalah tersebut. Namun, berdasarkan hasil riset Zhai *et al.* pada tahun 2019 menunjukkan bahwa hasil regularisasi *L2* memperoleh akurasi yang sangat baik dibandingkan dengan opsi lain untuk mengurangi *overfitting* selama tahap pelatihan (Zhai *et al.*, 2019).

Sehubungan dengan itu, pertanyaan penelitian yang saling terkait yang perlu diteliti lebih lanjut, antara lain tentang usulan model *GCLAMNET* dari hasil optimasi metode *contrast limited adaptive histogram equalization (CLAHE)* menggunakan teknik *gamma correction (GC)* untuk meningkatkan kualitas citra daun tanaman fitomedisin dengan *MobileNet (MNET)* sebagai klasifier data. Kedua, peningkatan hasil generalisasi

dari model pengenalan citra daun tanaman fitomedisin menggunakan teknik regularisasi $L2$ pada model *MNET*. Ketiga, usulan bentuk model baru dari *EGCLAMNETL* untuk pengenalan citra daun tanaman fitomedisin dengan cara melakukan *ensemble* antara model *GCLAMNET* dan model *MNETL2* menggunakan teknik *boosting*. Keempat adalah tentang bentuk model aplikasi pengenalan citra daun tanaman fitomedisin dengan mengimplementasikan model *EGCLAMNETL2*. Model *EGCLAMNETL* diusulkan sebagai kontribusi utama dari penelitian ini dengan justifikasi bahwa belum adanya penelitian yang mengajukan model tersebut untuk mengatasi permasalahan yang ada pada pengenalan citra daun tanaman fitomedisin baik dari segi dataset maupun kinerja metode yang diusulkan.

1.2. Rumusan Masalah

Untuk merumuskan permasalahan dan solusi yang ditawarkan berdasarkan latar belakang diatas maka dibuat beberapa poin yang menjadi poin penting dalam riset. Adapun rumusan masalah yang diteliti lebih lanjut antara lain:

1. Bagaimana bentuk model *GCLAMNET* dari hasil optimasi metode *contrast limited adaptive histogram equalization (CLAHE)* menggunakan teknik *gamma correction (GC)* untuk meningkatkan kualitas citra daun tanaman fitomedisin menggunakan klasifier *MobileNet (MNET)*?
2. Bagaimana bentuk model *EGCLAMNETL2* untuk identifikasi citra daun tanaman fitomedisin menggunakan teknik *ensemble boosting* antara model *MNET* model *GCLAMNET* dan model *MNETL* ?
3. Bagaimana bentuk prototipe aplikasi pengenalan citra daun tanaman fitomedisin dengan mengimplementasikan model *EGCLAMNETL* ?

1.3. Tujuan Penelitian

Adapun maksud atau tujuan dari riset ini antara lain:

1. Menganalisis hasil optimasi metode *contrast limited adaptive histogram equalization (CLAHE)* menggunakan teknik *gamma correction (GC)* untuk meningkatkan kualitas citra daun tanaman fitomedisin menggunakan

klasifier *MobileNet (MNET)*.

2. Mengusulkan bentuk model baru model baru *EGCLAMNETL* untuk pengenalan citra daun tanaman fitomedisin dengan cara melakukan *ensemble* antara model *GCLAMNET* dan model *MNETL2* menggunakan teknik *boosting*.
3. Mengusulkan bentuk prototipe aplikasi pengenalan citra daun tanaman fitomedisin dengan mengimplementasikan model *EGCLAMNETL* .

1.4. Manfaat Penelitian

Riset ini diharapkan dapat memberikan kontribusi bagi masyarakat akademik, masyarakat umum, pemerintah dan industri, diantaranya sebagai berikut:

1. Manfaat bagi masyarakat akademik yaitu memberikan rekomendasi dan referensi metode *contrast limited adaptive histogram equalization (CLAH)* menggunakan teknik *gamma correction (GC)* untuk meningkatkan kualitas citra daun tanaman fitomedisin menggunakan klasifier *MobileNet (MNET)* untuk meningkatkan hasil kualitas citra daun tanaman fitomedisin, memberikan referensi cara meningkatkan hasil generalisasi dari model pengenalan citra daun tanaman fitomedisin menggunakan teknik regularisasi *L2* pada model *MobileNet (MNET)*, menjadi sumber acuan baru tentang model baru *EGCLAMNETL2* untuk pengenalan citra daun tanaman fitomedisin dengan cara melakukan *ensemble* antara model *GCLAMNET* dan model *MNETL2* menggunakan teknik *boosting* dan memberikan pengetahuan baru mengenai bentuk model aplikasi pengenalan citra daun tanaman fitomedisin yang mengimplementasikan model *EGCLAMNETL2*.
2. Manfaat bagi masyarakat umum yaitu menyediakan media alternatif untuk mengidentifikasi daun tumbuhan fitomedisin dengan tepat. Selain itu, aplikasi pengenalan citra daun tanaman fitomedisin yang mengimplementasikan model *EGCLAMNETL2* ini bermanfaat untuk membantu penderita buta warna dan lansia mengenali daun tanaman fitomedisin agar tidak salah membedakan warna dan mengetahui jenis tanaman yang digunakan.

3. Manfaat bagi pemerintah yaitu mendukung program Kementerian Pertanian melalui Balai Penelitian Tanaman Rempah dan Obat (*Balittro*) dan Kementerian Kesehatan Republik Indonesia melalui Balai Besar Penelitian dan Pengembangan Tanaman Obat dan Obat Tradisional (*B2P2TO – TO*) untuk menyediakan aplikasi yang dapat digunakan untuk mengenali daun tanaman fitomedisin
4. Manfaat bagi industri yaitu membantu sosialisasi manfaat produk tanaman fitomedisin yang dikembangkan Usaha Mikro Kecil Menengah (*UMKM*) sampai industri besar sebagai alternatif pemeliharaan kesehatan bagi masyarakat.

1.5. Batasan Penelitian

Adapun batasan penelitian ini antara lain sebagai berikut:

1. Penelitian ini dilakukan di lima lokasi yang menjadi target objek penelitian di wilayah Sumatera Selatan, Bengkulu dan Jambi, antara lain Pondok Herbal Nisa dan Ihsan (Palembang), Sentra Tanaman Fitomedisin Naturamedica (Palembang), Kebun Tanaman Herbal Mapawo (Jambi), Taman Wisata Air Kito (Jambi) dan Agro Herbal Sejahtera (AHS) by Yayasan Sejahtera Bersama (Bengkulu).
2. Dataset citra fitomedisin adalah citra hasil penangkapan kamera (*capture*) dengan kamera digital (16.1 megapixel) yang diubah menjadi dimensi 512 x 512 pixel (dengan bantuan *software* Microsoft® Picture Manager dan Adobe Photoshop CS3).
3. Objek citra daun fitomedisin yang diambil adalah daun yang masih segar dari lingkungan hidup tanaman secara langsung.
4. Data citra dari penelitian ini merupakan daun tanaman yang direkomendasikan oleh Kementerian Kesehatan Republik Indonesia berdasarkan “Keputusan Menteri Kesehatan Republik Indonesia Nomor HK.01.07/Menkes/187/2017” tentang “Formularium Ramuan Obat Tradisional Indonesia” yang berkaitan dengan imunitas tubuh manusia, antara lain daun asam jawa, daun belimbing wuluh, daun ekor naga, daun jambu biji, daun jintan, daun kelor, daun kumis

kucing, daun lidah buaya, daun mimba, daun pegagan, daun pepaya, daun salam, daun sambiloto, daun sirih dan daun sirsak.

1.6. Sistematika Penulisan

Sistematika penulisan disertasi terdiri dari enam bab sebagai berikut Pendahuluan, Tinjauan Pustaka, Metodologi, Pengembangan Model Deep Learning, Pengembangan Prototipe Aplikasi serta Kesimpulan dan Saran. Bab Pendahuluan berisi latar belakang, rumusan masalah, batasan masalah, tujuan dan manfaat, metodologi serta sistematika penulisan. Pada Bab Tinjauan Pustaka dibahas tentang teori mengenai tanaman fitomedisin, augmentasi data, *contrast enhancement*, *deep learning* dan metode pengembangan aplikasi. Bab Pengembangan Model Deep Learning terdiri dari sub bab antara lain persiapan dataset dan pengembangan model *deep learning*. Pada Bab Pengembangan Prototipe Aplikasi dibahas tentang *feature modelling* (FM) dan *unified modelling language* (UML) untuk memodelkan aplikasi. Pada Kesimpulan dan Saran dibahas tentang kesimpulan dan saran peneliti.

DAFTAR PUSTAKA

- Ahila Priyadarshini, R., Arivazhagan, S., & Arun, M. (2020). Ayurvedic Medicinal Plants Identification: A Comparative Study on Feature Extraction Methods. *International Conference on Computer Vision and Image Processing*, 268–280. Springer. doi: https://doi.org/10.1007/978-981-16-1092-9_23
- Akter, R., & Hosen, M. I. (2020). CNN-based Leaf Image Classification for Bangladeshi Medicinal Plant Recognition. *2020 Emerging Technology in Computing, Communication and Electronics (ETCCE)*, 1–6. doi: 10.1109/ETCCE51779.2020.9350900
- Alshammari, T. O., Pilakoutas, K., & Guadagnini, M. (2023). Performance of Manufactured and Recycled Steel Fibres in Restraining Concrete Plastic Shrinkage Cracks. *Materials*, 16(2), 713.
- Ansari, A. S., Jawarneh, M., Ritonga, M., Jamwal, P., Mohammadi, M. S., Veluri, R. K., ... Shah, M. A. (2022). Improved Support Vector Machine and Image Processing Enabled Methodology for Detection and Classification of Grape Leaf Disease. *Journal of Food Quality*, 2022. doi: 10.1155/2022/9502475
- Anubha, S. P., Sathiesh Kumar, V., & Harini, S. (2019). A study on plant recognition using conventional image processing and deep learning approaches. *Journal of Intelligent & Fuzzy Systems*, 36(3), 1997–2004. doi: <https://doi.org/10.3233/JIFS-169911>
- Arji, G., Safdari, R., Rezaeizadeh, H., Abbassian, A., Mokhtaran, M., & Hossein Ayati, M. (2019). A systematic literature review and classification of knowledge discovery in traditional medicine. *Computer Methods and Programs in Biomedicine*, 168, 39–57. doi: <https://doi.org/10.1016/j.cmpb.2018.10.017>
- Azeez, Y. R., & Rajapakse, C. (2019). An Application of Transfer Learning Techniques in Identifying Herbal Plants in Sri Lanka. *2019 International Research Conference on Smart Computing and Systems Engineering (SCSE)*, 172–178. doi: 10.23919/SCSE.2019.8842681
- Azwar, A., & Jacob, T. (1992). *Antropologi Kesehatan Indonesia Jilid 1*. Jakarta: Penerbit Buku Kedokteran EGC.
- Balitkes. (2013). *Riset Kesehatan Dasar 2013*. Jakarta.
- Barbosa, W. L. R., do Nascimento, M. S., do Pinto, L. N., Maia, F. L. C., Sousa, A. J. A., Júnior, J., & de Oliveira, D. R. (2012). Selecting medicinal plants for development of phytomedicine and use in primary health care. *Bioactive Compounds in Phytomedicine*, 3–24. doi: <https://doi.org/10.5772/26078>
- Bloice, M. D., Stocker, C., & Holzinger, A. (2017). Augmentor: an image augmentation library for machine learning. *ArXiv Preprint ArXiv:1708.04680*.

- Brownlee, J. (2021). A Gentle Introduction to Ensemble Learning Algorithms. Retrieved from Machine Learning Mastery website: <https://machinelearningmastery.com/tour-of-ensemble-learning-algorithms/>
- Cao, G., Huang, L., Tian, H., Huang, X., Wang, Y., & Zhi, R. (2018). Contrast enhancement of brightness-distorted images by improved adaptive gamma correction. *Computers & Electrical Engineering*, *66*, 569–582.
- Chethan, K. S., Donepudi, S., Supreeth, H. V., & Maani, V. D. (2021). *Mobile Application for Classification of Plant Leaf Diseases Using Image Processing and Neural Networks BT - Data Intelligence and Cognitive Informatics* (I. Jeena Jacob, S. Kolandapalayam Shanmugam, S. Piramuthu, & P. Falkowski-Gilski, Eds.). Singapore: Springer Singapore.
- Dahigaonkar, T. D., & Kalyane, R. (2018). Identification of ayurvedic medicinal plants by image processing of leaf samples. *International Research Journal of Engineering and Technology (IRJET)*, *5*(05).
- Dat, T. T., Vu, P. C. L. T., Truong, N. N., Sang, V. N. T., & Bao, P. T. (2021). Leaf recognition based on joint learning multiloss of multimodel convolutional neural networks: a testing for Vietnamese herb. *Computational Intelligence and Neuroscience*, *2021*.
- Dileep, M. R., & Pournami, P. N. (2019). AyurLeaf: A Deep Learning Approach for Classification of Medicinal Plants. *TENCON 2019 - 2019 IEEE Region 10 Conference (TENCON)*, 321–325. doi: 10.1109/TENCON.2019.8929394
- Ghaderizadeh, S., Abbasi-Moghadam, D., Sharifi, A., Zhao, N., & Tariq, A. (2021). Hyperspectral Image Classification Using a Hybrid 3D-2D Convolutional Neural Networks. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *14*, 7570–7588. doi: 10.1109/JSTARS.2021.3099118
- Goeswin, A. (2007). *Teknologi Bahan Alam. Bandung*. Penerbit ITB.
- Hao, R., Namdar, K., Liu, L., Haider, M. A., & Khalvati, F. (2021). A comprehensive study of data augmentation strategies for prostate cancer detection in diffusion-weighted MRI using convolutional neural networks. *Journal of Digital Imaging*, *34*, 862–876.
- Harjanti, T Wira, Madenda, S., Harlan, J., & Lussiana, E. T. P. (2020). Study and Research on the Identification of the Leaves of Indonesian Herbal Medicines Using Manhattan Distance and Neural Network Algorithms. *2020 Fifth International Conference on Informatics and Computing (ICIC)*, 1–6. doi: 10.1109/ICIC50835.2020.9288564
- Harjanti, Trinugi Wira, & Himawan, H. (2021). Teknologi Pengolahan Citra Digital Untuk Ekstraksi Ciri pada Citra Daun untuk Identifikasi Tumbuhan Obat. *Faktor Exacta*, *14*(3), 150–159. doi: <https://doi.org/10.30998/faktorexacta.v14i3.9841>

- Haryono, Anam, K., & Saleh, A. (2020). A Novel Herbal Leaf Identification and Authentication Using Deep Learning Neural Network. *2020 International Conference on Computer Engineering, Network, and Intelligent Multimedia (CENIM)*, 338–342. doi: 10.1109/CENIM51130.2020.9297952
- Hoffman, J. (2018). *Cramnet: layer-wise deep neural network compression with knowledge transfer from a teacher network*. The University of Tulsa.
- Holleman, M. (2017). MobileNet version 2.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *ArXiv Preprint ArXiv:1704.04861*.
- Jafar, A., & Lee, M. (2021). High-speed hyperparameter optimization for deep ResNet models in image recognition. *Cluster Computing*, 1–9. doi: <https://doi.org/10.1007/s10586-021-03284-6>
- Jamaliah, I., Whidhiasi, R. N., & Maimunah, M. (2017). Identifikasi Jenis Daun Tanaman Obat Hipertensi Berdasarkan Citra Rgb Menggunakan Jaringan Syaraf Tiruan. *PIKSEL: Penelitian Ilmu Komputer Sistem Embedded and Logic*, 5(1), 1–11.
- Janani, R., & Gopal, A. (2013). Identification of selected medicinal plant leaves using image features and ANN. *2013 International Conference on Advanced Electronic Systems (ICAES)*, 238–242. doi: 10.1109/ICAES.2013.6659400
- Javed, M. (2014). Towards the maturity model for feature oriented domain analysis. *Computational Ecology and Software*, 4(3), 170.
- Kandel, I., Castelli, M., & Manzoni, L. (2022). Brightness as an augmentation technique for image classification. *Emerging Science Journal*, 6(4), 881–892.
- Kang, K. C., Cohen, S. G., Hess, J. A., Novak, W. E., & Peterson, A. S. (1990). *Feature-oriented domain analysis (FODA) feasibility study*. Carnegie-Mellon Univ Pittsburgh Pa Software Engineering Inst. doi: <https://doi.org/10.21236/ADA235785>
- Katno. (2008). *Tingkat Manfaat Keamanan dan Efektifitas Tanaman Obat dan Obat Tradisional*. Tawangmangu: Balai Besar Tanaman Obat dan Obat Tradisional.
- Khasoggi, B., Ermatita, E., & Sahmin, S. (2019). Efficient mobilenet architecture as image recognition on mobile and embedded devices. *Indones. J. Electr. Eng. Comput. Sci*, 16, 389–394. doi: <https://doi.org/10.11591/ijeecs.v16.i1.pp389-394>
- Luque, A., Carrasco, A., Martín, A., & de Las Heras, A. (2019). The impact of class imbalance in classification performance metrics based on the binary confusion matrix. *Pattern Recognition*, 91, 216–231. doi: <https://doi.org/10.1016/j.patcog.2019.02.023>
- Ma, J., Fan, X., Yang, S. X., Zhang, X., & Zhu, X. (2018). Contrast Limited Adaptive

Histogram Equalization-Based Fusion in YIQ and HSI Color Spaces for Underwater Image Enhancement. *International Journal of Pattern Recognition and Artificial Intelligence*, 32(07), 1854018. doi: 10.1142/S0218001418540186

- Maulidiya, D., & Kasrina, K. (2016). Pengembangan Modul Inventarisasi Tanaman Obat Pada Sistem Informasi Tanaman Obat Bengkulu. *Jurnal Media Infotama*, 12(2).
- Nithiyanandhan, K., & Reddy, T. B. (2017). Analysis of the leaf veins and areoles in different medicinal leaves by using image processing techniques. *International Journal of Advanced Research in Computer Science*, 8(5).
- Nurnaningsih, D., Alamsyah, D., Herdiansah, A., & Sinlae, A. A. J. (2021). Identifikasi Citra Tanaman Obat Jenis Rimpang dengan Euclidean Distance Berdasarkan Ciri Bentuk dan Tekstur. *Building of Informatics, Technology and Science (BITS)*, 3(3), 171–178. doi: <https://doi.org/10.47065/bits.v3i3.1019>
- Oppermann, A. (2020). Regularization in Deep Learning — L1, L2, and Dropout. Retrieved from Towards Data Science website: <https://towardsdatascience.com/regularization-in-deep-learning-l1-l2-and-dropout-377e75acc036>
- Peña, L. E. R., Calderon, H. A., & Carsteanu, A. A. (2022). Digital Image Processing in C++ in SEM Images. *Microscopy and Microanalysis*, 28(S1), 2186–2188.
- Pérez-Nicolás, M., Vibrans, H., Romero-Manzanares, A., Saynes-Vásquez, A., Luna-Cavazos, M., Flores-Cruz, M., & Lira-Saade, R. (2017). Patterns of knowledge and use of medicinal plants in Santiago Camotlán, Oaxaca, Mexico. *Economic Botany*, 71(3), 209–223. doi: <https://doi.org/10.1007/s12231-017-9384-0>
- Phumthum, M., Balslev, H., & Barfod, A. S. (2019). Important medicinal plant families in Thailand. *Frontiers in Pharmacology*, 10, 1125. doi: <https://doi.org/10.3389/fphar.2019.01125>
- Pujara, A. (2020). Image Classification With MobileNet. Retrieved August 10, 2022, from Medium website: <https://medium.com/analytics-vidhya/image-classification-with-mobilenet-cc6fbb2cd470>
- Quoc, T. N., & Hoang, V. T. (2020). Medicinal Plant identification in the wild by using CNN. *2020 International Conference on Information and Communication Technology Convergence (ICTC)*, 25–29. doi: 10.1109/ICTC49870.2020.9289480
- Rahman, S., Rahman, M. M., Abdullah-Al-Wadud, M., Al-Quaderi, G. D., & Shoyaib, M. (2016). An adaptive gamma correction for image enhancement. *EURASIP Journal on Image and Video Processing*, 2016(1), 35. doi: 10.1186/s13640-016-0138-1
- Rice, L., Wong, E., & Kolter, Z. (2020). Overfitting in adversarially robust deep learning. *International Conference on Machine Learning*, 8093–8104. PMLR.
- Riska, S. Y., Cahyani, L., & Rosadi, M. I. (2015). Klasifikasi jenis tanaman mangga

gadung dan mangga madu berdasarkan tulang daun. *Jurnal Buana Informatika*, 6(1). doi: <https://doi.org/10.24002/jbi.v6i1.399>

- Rosebrock, A. (2016). Understanding Regularization for Image Classification and Machine Learning. Retrieved from PyImageSearch website: <https://pyimagesearch.com/2016/09/19/understanding-regularization-for-image-classification-and-machine-learning/>
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... Bernstein, M. (2015). Imagenet large scale visual recognition challenge. *International Journal of Computer Vision*, 115(3), 211–252. doi: <https://doi.org/10.1007/s11263-015-0816-y>
- Sae-Lim, W., Wettayaprasit, W., & Aiyarak, P. (2019). Convolutional neural networks using MobileNet for skin lesion classification. *2019 16th International Joint Conference on Computer Science and Software Engineering (JCSSE)*, 242–247. IEEE. doi: <https://doi.org/10.1109/JCSSE.2019.8864155>
- Sahu, S., Singh, A. K., Ghrera, S. P., & Elhoseny, M. (2019). An approach for de-noising and contrast enhancement of retinal fundus image using CLAHE. *Optics & Laser Technology*, 110, 87–98.
- Sandler, M., & Howard, A. (2018). MobileNetV2: The Next Generation of On-Device Computer Vision Networks.
- Singh, U. P., Chouhan, S. S., Jain, S., & Jain, S. (2019). Multilayer Convolution Neural Network for the Classification of Mango Leaves Infected by Anthracnose Disease. *IEEE Access*, 7, 43721–43729. doi: [10.1109/ACCESS.2019.2907383](https://doi.org/10.1109/ACCESS.2019.2907383)
- Somasundaram, K., & Kalavathi, P. (2011). Medical image contrast enhancement based on gamma correction. *Int J Knowl Manag E-Learning*, 3(1), 15–18.
- Springenberg, J. T., Dosovitskiy, A., Brox, T., & Riedmiller, M. (2014). Striving for simplicity: The all convolutional net. *ArXiv Preprint ArXiv:1412.6806*.
- Syam, A. A., Rifka, S., & Aulia, S. (2021). Implementasi Pengolahan Citra Untuk Identifikasi Daun Tanaman Obat Menggunakan Levenberg-Marquardt Backpropagation. *Elektron: Jurnal Ilmiah*, 1–8. doi: <https://doi.org/10.30630/eji.0.0.176>
- Thanikkal, J. G., Dubey, A. K., & Thomas, M. T. (2018). Advanced Plant Leaf Classification Through Image Enhancement and Canny Edge Detection. *2018 7th International Conference on Reliability, Infocom Technologies and Optimization: Trends and Future Directions, ICRITO 2018*, 518–522. doi: [10.1109/ICRITO.2018.8748587](https://doi.org/10.1109/ICRITO.2018.8748587)
- Udendhran, R., Balamurugan, M., Suresh, A., & Varatharajan, R. (2020). Enhancing image processing architecture using deep learning for embedded vision systems. *Microprocessors and Microsystems*, 76, 103094.

- Visual Paradigm. (2020). What is Unified Modeling Language (UML)?
- Wang, Z., Xu, M., & Zhang, Y. (2022). Review of quantum image processing. *Archives of Computational Methods in Engineering*, 29(2), 737–761.
- Wasil, M., Harianto, H., & Fathurrahman, F. (2022). Pengaruh epoch pada akurasi menggunakan convolutional neural network untuk klasifikasi fashion dan furniture. *Info: Jurnal Informatika Dan Teknologi*, 5(1), 53–61. doi: <https://doi.org/10.29408/jit.v5i1.4393>
- Yudho, S., & Daryanto, T. (2018). Penyusunan Feature Model dengan Pendekatan Foda. Studi Kasus Aplikasi Elearning Universitas Mercubuana. *Petir*, 11(1), 67–71. doi: <https://doi.org/10.33322/petir.v11i1.12>
- Zahisham, Z., Lee, C. P., & Lim, K. M. (2020). Food recognition with ResNet-50. *2020 IEEE 2nd International Conference on Artificial Intelligence in Engineering and Technology (IICAIET)*, 1–5. IEEE. doi: <https://doi.org/10.1109/IICAIET49801.2020.9257825>
- Zein, U. (2005). Pemanfaatan tumbuhan obat dalam upaya pemeliharaan kesehatan. *Univ Sumatra Utara, Medan*, 23, 1–7.
- Zhai, Y., Deng, W., Xu, Y., Ke, Q., Gan, J., Sun, B., ... Piuri, V. (2019). Robust sar automatic target recognition based on transferred ms-cnn with l2-regularization. *Computational Intelligence and Neuroscience*, 2019. doi: <https://doi.org/10.1155/2019/9140167>