

TPHerbleaf : Dataset Untuk Klasifikasi Jenis Daun Tumbuhan Herbal Berdasarkan Lontar Usada Taru Pramana

Ni Putu Dita Ariani Sukma Dewi¹, Made Windu Antara Kesiman², I Made Gede Sunarya³, I Gusti Ayu Agung Diatri Indradewi⁴, I Gede Andika⁵

^{1,2,3,4}Program Studi Ilmu Komputer, Universitas Pendidikan Ganesha
Jl. Udayana No. 11, Banyuasri, Kabupaten Buleleng

⁵Sistem Komputer, Institut Bisnis dan Teknologi Indonesia
Jl. Tukad Pakerisan No 97, Denpasar, Indonesia

e-mail: dita.ariani.sukma@undiksa.ac.id¹, antara.kesiman@undiksa.ac.id², sunarya@undiksha.ac.id³,
indradewi@undiksha.ac.id⁴, gdandika@instiki.ac.id⁵

Received : Juli, 2023

Accepted : Agustus, 2023

Published : Agustus, 2023

Abstract

Herbal plants are types of plants that are used in the health sector. Herbal plants are generally recognized by their leaves because leaves are easily found compared to other plant parts such as flowers, fruits, or roots. However, a lack of understanding about the types of herbal plants and similarity of leaf morphology is a challenge encountered in the introduction of herbal plants, making it difficult to recognize herbal plants, especially for people who do not have botanical knowledge. This study aims to create a dataset of leaf images of herbal plants called TPHerbleaf. This dataset will be used to recognize and classify the types of leaves of herbal plants, based on Usada Taru Pramana Manuscript which is the Balinese people's indigenous wisdom in traditional medicine and has been studied scientifically. The classification of herbal plants using EfficientNet B2 produce accuracy value 97.5% for training, 81.77% for validation, and 83.49% for testing. By combining traditional knowledge with modern technology, this research is expected to contribute understanding and preserving cultural heritage through practical applications of image classification.

Keyword: Dataset, Herbal Plants, Classification, Usada Taru Pramana, TPHerbleaf

Abstrak

Tumbuhan herbal ialah jenis tumbuhan yang dimanfaatkan dalam bidang kesehatan. Tumbuhan herbal umumnya dikenali dari daunnya karena daun mudah dibandingkan dengan bagian tumbuhan lainnya seperti bunga, buah, atau akarnya. Minimnya pengetahuan mengenai jenis tumbuhan herbal dan kemiripan jenis morfologi daun merupakan tantangan yang ditemui dalam pengenalan tumbuhan herbal, sehingga sulit untuk mengenali tumbuhan herbal terutama bagi orang yang tidak memiliki pengetahuan botani. Penelitian ini bertujuan untuk membuat dataset citra daun tumbuhan herbal bernama TPHerbleaf. Dataset ini akan digunakan untuk mengenali dan mengklasifikasikan jenis daun tumbuhan herbal berpedoman pada Lontar Usada Taru Pramana yang merupakan kearifan lokal masyarakat Bali dalam pengobatan tradisional dan telah dikaji secara ilmiah. Metode untuk klasifikasi tumbuhan herbal menggunakan EfficientNet B2 yang menghasilkan nilai akurasi 97,5% untuk training, 81,77% untuk validation, dan 83,49% untuk testing. Dengan menggabungkan pengetahuan tradisional dengan teknologi modern, penelitian ini diharapkan dapat memberikan kontribusi dalam meningkatkan pemahaman serta pelestarian warisan budaya melalui aplikasi praktis dalam bidang klasifikasi citra.

Kata Kunci: Dataset, Tumbuhan Herbal, Klasifikasi, Lontar Usada Taru Pramana, TPHerbleaf

1. PENDAHULUAN

Tumbuhan memegang peranan sentral dalam ekosistem dan memberikan beragam manfaat yang sangat penting bagi keberlangsungan kehidupan manusia. Tercatat sebesar 374.000 jenis tumbuhan yang ada di dunia [1]. Selain sebagai penghasil oksigen terbesar, tumbuhan juga menjadi pusat perhatian dalam bidang kesehatan manusia, adapun jenis-jenis tumbuhan yang digunakan secara khusus dipergunakan sebagai pengobatan dalam bidang kesehatan, dikatakan sebagai tumbuhan herbal [2]. Masih ada sekitar 80% orang yang bergantung pada tumbuhan herbal kesehatan manusia [3]. Salah satu contoh penggunaan tumbuhan herbal sebagai pengobatan tradisional tercatat dalam kearifan lokal Bali yakni Lontar Usada Taru Pramana [4]. Terdapat sekitar 180 jenis tumbuhan herbal yang dapat digunakan sebagai pengobatan tradisional [5]. Terkait jumlahnya yang begitu besar dan beragam, proses klasifikasi tumbuhan herbal memang memerlukan sejumlah waktu yang relatif panjang. Tidak hanya itu, tugas klasifikasi ini juga dihadapkan pada tantangan konvensional yang cukup rumit. Selain batasan dalam pengetahuan yang dimiliki mengenai tumbuhan herbal, tumbuhan-tumbuhan herbal ini seringkali sulit dikenali secara akurat, mengingat terdapat kesamaan dalam morfologi di antara beberapa spesies tersebut. Kesalahan klasifikasi juga mengakibatkan kesalahan dalam komposisi racikan tumbuhan herbal dengan tujuan pengobatan [3]. Melihat kondisi tersebut, muncul kebutuhan akan pengembangan suatu sistem klasifikasi tumbuhan herbal yang bersifat otomatis. Sistem ini memiliki tujuan untuk membantu manusia dalam mengenali jenis-jenis tanaman herbal dengan akurasi tinggi dan dalam waktu cepat serta kedepannya diharapkan bahwa bahkan individu dengan pengetahuan botani yang terbatas pun akan mampu mengidentifikasi tanaman herbal dengan mudah. Maka dari itu, keberadaan sistem klasifikasi otomatis menjadi sangat krusial dalam menjembatani kesenjangan pengetahuan dan mengatasi tantangan klasifikasi dalam upaya pelestarian serta pemanfaatan kekayaan alam dalam bentuk tumbuhan herbal.

Secara umum, tumbuhan herbal dapat dikenali melalui bagian batang, bunga, buah, dan

daunnya. Penelitian ini berfokus pada bagian tumbuhan yang paling stabil dalam bentuk, usia, dan teksturnya yakni daun. Daun juga merupakan bagian tumbuhan yang paling mudah diakses dan paling tahan terhadap perubahan [6].

Dataset *Flavia* dan Dataset *Swedish Leaf* merupakan dataset jenis tumbuhan herbal yang paling banyak digunakan, dengan gambar laboratorium yang tersedia. Dataset ini telah banyak digunakan untuk melatih arsitektur CNN untuk klasifikasi jenis tumbuhan. Model yang dilatih pada dataset ini mampu mencapai akurasi klasifikasi yang tinggi selama pelatihan. Namun ketika sistem ini diuji dibawah kondisi lapangan yang sebenarnya, kinerjanya menurun tajam. Hal ini disebabkan karena perbedaan gambar laboratorium yang bersih tanpa latar belakang, dengan gambar yang dikumpulkan langsung di lapangan yang memiliki fitur latar belakang yang kompleks, termasuk batang, buah, tanah, dan daun sekitarnya [7][8]. Batasan lain dari dataset *Flavia* dan *Swedish Leaf* seperti jumlah spesies tumbuhan yang terbatas dan sampel per spesies, serta variasi format dan kualitas gambar, juga dapat berkontribusi pada penurunan kinerja jaringan saraf dalam kondisi lapangan yang sebenarnya. Dataset-dataset ini mungkin tidak sepenuhnya menangkap keragaman dan kompleksitas gambar lapangan dunia nyata, yang menyebabkan tantangan dalam mengklasifikasikan tumbuhan dengan akurat dalam lingkungan tersebut [7] [9].

Mengatasi tantangan tersebut, pada penelitian ini diusulkan TPherleaf sebagai dataset baru dengan 50 jenis daun tumbuhan herbal berdasarkan Lontar Usada Taru Pramana. Dengan mengumpulkan data daun berdasarkan naskah ini, diharapkan dapat mengatasi keterbatasan dataset yang ada dan membuat dataset yang lebih beragam dan komprehensif untuk penelitian klasifikasi citra daun. Naskah Usada Taru Pramana berisi pengetahuan pengobatan tradisional Bali tentang berbagai tanaman dan khasiat obatnya, yang dapat memberikan sifat tanaman yang unik dan potensi untuk penemuan baru [10]. Mengumpulkan data daun dari naskah ini juga dapat membantu melestarikan dan mempromosikan warisan budaya Bali [10]. Dataset TPherleaf yang diusulkan juga diharapkan dapat membantu meningkatkan

akurasi model karena gambar yang diambil seluruhnya masih dalam kondisi sebenarnya saat di lapangan (background natural).

Data citra daun pada dataset TPHerbleaf dikumpulkan dari beberapa daerah di Bali yakni Kabupaten Badung, Kabupaten Tabanan, dan Kota Denpasar. Pengumpulan data daun dari berbagai lokasi bertujuan untuk memperkaya variasi citra daun dalam dataset. Hal ini memungkinkan sistem yang diusulkan untuk lebih akurat dan luas dalam mempelajari berbagai bentuk, ukuran, dan warna daun dari setiap jenis, karena variasi tersebut bervariasi antar lokasi [11]. Klasifikasi pada CNN memerlukan jumlah data latihan yang besar. Untuk meningkatkan data, berbagai teknik augmentasi diterapkan agar model dapat belajar dari gambar yang sama namun dengan arah dan kondisi yang berbeda, hal ini kemudian dapat membantu meningkatkan kinerja model dalam memprediksi gambar-gambar yang belum pernah dilihat sebelumnya [12].

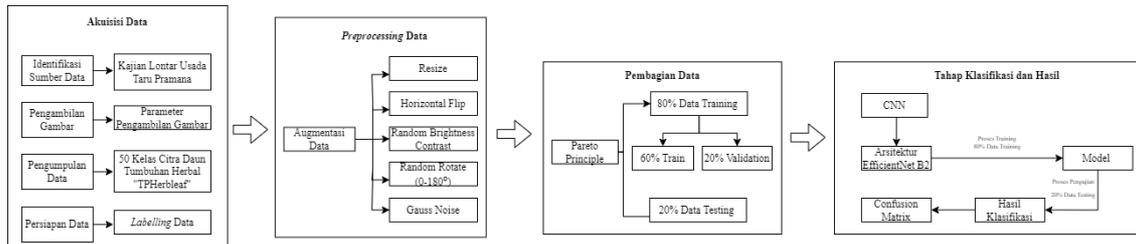
Klasifikasi citra daun menggunakan sampel data berdasarkan kesamaan fitur warna, bentuk, dan tekstur daun. Metode *machine learning* atau *deep learning* dapat digunakan dalam proses klasifikasi. Penelitian [13] menunjukkan bahwa *machine learning* sulit diaplikasikan pada kondisi dunia nyata, sementara *deep learning* terbukti lebih tepat karena dapat beradaptasi dengan latar belakang yang lebih kompleks pada dataset. Inilah dasar pemilihan metode *deep learning* dalam penelitian ini untuk mengidentifikasi tumbuhan herbal dengan kondisi lapangan.

Salah satu metode yang dirancang untuk memproses data dalam bentuk gambar dan sering digunakan pada kasus klasifikasi gambar ialah *Convolutional Neural Network* (CNN) [3]. Berdasarkan beberapa penelitian terdahulu, dimulai dari penelitian oleh Felix, dkk pada tahun 2020 dengan judul Implementasi Convolutional Neural Network Untuk Identifikasi Jenis Tanaman Melalui Daun” [14]. Implementasi CNN pada penelitian ini adalah pendeteksian jenis daun berjumlah 5 kelas dari

Swedish Leaf Dataset. Hasil dari tahap pengujian menyatakan bahwa CNN mempunyai akurasi yang baik dengan nilai akurasi 76%. Selanjutnya adalah penelitian dari Akter dan Hosen tahun 2020 dengan judul “*CNN-based Leaf Image Classification for Bangladeshi Medicinal Plant Recognition*” yang mengimplementasikan CNN untuk klasifikasi 10 jenis tumbuhan herbal dari negara Bangladesh [1]. Hasil pengujian menggunakan algoritma CNN dalam penelitian ini menghasilkan tingkat akurasi sebesar 71,3%. Selanjutnya adalah penelitian dari Sreenath, dkk tahun 2021 dengan judul “*Deep Learning Classification of Lake Zooplankton*” [15]. Penelitian ini mengimplementasikan CNN dengan teknik *transfer learning* dengan beberapa arsitektur yakni *EfficientNet B0-B7*, *InceptionV3*, *DenseNet121*, *MobileNet*, dan *ResNet50* untuk klasifikasi jenis-jenis *zooplankton* yang ditemukan di danau. Model dengan F-1 Score terbaik adalah *EfficientNet B2* dan *EfficientNet B7* dengan hasil 90% diikuti dengan *MobileNet* dengan hasil 89.1% dan memiliki parameter yang lebih sedikit. Penelitian ini menyimpulkan bahwa *EfficientNet B2* dan *MobileNet* memberikan keseimbangan baik antara kinerja dan ukuran model. *Transfer learning* terbukti mempercepat pelatihan dan meningkatkan kinerja model. Penelitian selanjutnya dilakukan oleh Aras, dkk tahun 2022 dengan judul “*Deep Learning Untuk Klasifikasi Motif Batik Papua Menggunakan EfficientNet dan Transfer Learning*” [16]. Penelitian ini menggunakan CNN dengan *EfficientNet B2* dan *transfer learning* untuk mengklasifikasi motif batik dari Papua, mencakup empat kelas: Batik Cendrawasih, Batik Tifa Honai, Batik Asmat, dan Batik Raja Ampat. Dengan fine tuning, akurasi mencapai 72%. Dengan penambahan augmentasi tinggi menggunakan teknik *ColorJitter* dan *Contrast*, akurasi meningkat menjadi 90%.

Berdasarkan paparan masalah dan beberapa penelitian terkait sebelumnya, penelitian ini akan mengklasifikasi daun tanaman herbal dari dataset TPHerbleaf menggunakan arsitektur Convolutional Neural Network (CNN), yaitu *EfficientNet B2*.

2. METODE PENELITIAN



Gambar 1. Alur Penelitian

Bagan pada Gambar 1 diatas merupakan diagram alur yang berisikan penjelasan tentang tahap-tahap penelitian sampai pada hasil dari penelitian. Terdapat 4 tahapan yang ada pada penelitian ini dimulai dari akuisisi data untuk dataset TPHerbleaf, lalu *preprocessing* data, pembagian data, dan tahap akhir adalah tahap klasifikasi dan hasil.

2.1 Akuisisi Dataset

Akuisisi data adalah bagian dari analisis metode pengambilan citra daun yang akan digunakan dalam penelitian. Proses ini dimulai dengan identifikasi sumber data, mengambil gambar, mengumpulkannya, dan kemudian memproses gambar untuk menghasilkan data yang diharapkan.

Proses identifikasi sumber data menggunakan pedoman kajian ilmiah Lontar Usada Taru Pramana oleh I Wayan Sukersa tahun 2017 [4], Sutomo dan Rajif I. tahun 2019 [5], dan Putu Eka Sura Adnyana tahun 2021 [17]. 50 jenis tumbuhan herbal ditemukan dari literatur tersebut yang akan digunakan sebagai kelas citra daun dalam penelitian.

Proses pengambilan data citra daun dilakukan dengan mengunjungi langsung lokasi tumbuhan herbal tersebut di Bali, lalu mengambil gambar langsung dari daun dengan parameter pengambilan gambar dan spesifikasi data gambar sebagai berikut.

- 1) Citra daun diambil dengan menggunakan kamera smartphone dengan kamera utama 9 MP, resolusi citra asli yang dihasilkan adalah 3024x3024 piksel [18].
- 2) Agar objek foto tampak jelas saat pengambilan gambar, jarak pengambilan objek harus sesuai dengan ukuran dan letak

tumbuhan, dan tidak lebih dari satu meter [19].

- 3) Gambar diambil di tempat dengan pencahayaan yang cukup [19].

Kontribusi dari akuisisi dataset antara lain:

- 1) Data citra daun pada dataset TPHerbleaf dikumpulkan dari beberapa daerah di Bali yakni Kabupaten Badung, Kabupaten Tabanan, dan Kota Denpasar. Pengumpulan data daun dari berbagai lokasi bertujuan untuk memperkaya variasi citra daun dalam dataset [11].
- 2) Berbagai teknik validasi data telah diterapkan untuk memastikan kualitas dan keandalan dataset. Teknik-teknik ini meliputi *labelling* data dengan bantuan *key person* atau ahli, dan langkah-langkah preprocessing seperti *resizing* gambar dan teknik augmentasi lainnya.

Tabel 1 berisi rincian yang mendalam mengenai 50 variasi jenis daun tumbuhan herbal yang tersedia dalam dataset TPHerbleaf. Setiap jenis daun disajikan dengan gambar visual yang menggambarkan citra daun dari jenis tersebut, dan disertai dengan informasi mengenai penggunaannya dalam konteks pengobatan tradisional atau herbal. Pengumpulan data menghasilkan total 1000 gambar asli dari berbagai jenis daun, dengan distribusi sebanyak 20 gambar di setiap kelas yang ada.

Tabel 1: Rincian Data Jenis Daun Tumbuhan Herbal dari Dataset TPHerbleaf
 [Sumber : [4][5][17]]

No. Label Kelas	Citra Daun	Nama Kelas	Kegunaan	No. Label Kelas	Citra Daun	Nama Kelas	Kegunaan
0		Ancak	Getahnya dapat dipergunakan untuk pengobatan lelah.	25		Lantana	Daunnya untuk obat mual.
1		Awar Awar	Daun dan akar digunakan sebagai jamu untuk mengobati muntaber dan gigitan ular belang.	26		Legundi	Daunnya dapat digunakan untuk sakit demam.
2		Beringin	Pengobatan sakit perut dengan kayu, akar, dan daun.	27		Mangga Amplem	Serat kayunya digunakan untuk obat sakit perut samping.
3		Cemara	Pengobatan sakit mata dan sakit <i>magic</i> "jaran guying".	28		Manggis	Getahnya digunakan untuk obat tilas naga.
4		Cempaka Kuning	Sisik kayunya digunakan untuk obat susah tidur.	29		Mengkudu	Buahnya digunakan untuk obat maag.
5		Ceremai	Buahnya dipergunakan untuk obat luka di jari	30		Merica	Daunnya digunakan untuk obat sakit kepala.
6		Dapdap	Daun dan kayunya untuk obat perut kembung.	31		Nanas	Buahnya digunakan untuk obat kencing nanah.
7		Delima	Seluruh bagian tumbuhan dapat digunakan untuk obat sakit perut.	32		Pakis Sayur	Daunnya digunakan untuk meningkatkan nafsu makan.
8		Gadung	Akar dan buahnya untuk obat bisul.	33		Pala	Serat kayunya digunakan untuk obat penyakit dalam.

9		Jambu Air	Air rebusan daunnya untuk obat demam anak.	34		Pare	Daun dan akar untuk obat pingsan.
10		Jambu Biji	Daun untuk obat diare.	35		Pepaya	Getahnya digunakan untuk mengobati gigitan kelabang.
11		Jarak Pagar	Serat kayunya untuk mengobati tuli.	36		Pule	Daunnya digunakan untuk obat panas dalam.
12		Jeruk Limau	Akar dan daun untuk obat kesemutan dan rematik.	37		Salam	Rebusan daunnya digunakan untuk obat rematik.
13		Jeruk Sitrun	Daunnya untuk obat pegal.	38		Semanggi	Daunnya digunakan untuk obat koreng kulit.
14		Juwet	Buahnya dipergunakan untuk obat penyakit sipilis.	39		Sembung	Buahnya digunakan untuk obat panas dalam perut.
15		Kaca Piring	Daunnya digunakan sebagai obat saat sakit dan tidak nafsu makan.	40		Sirih	Daunnya digunakan untuk obat pegal.
16		Kamboja	Serat kayunya untuk obat sakit pinggang.	41		Sirsak	Getah dan daunnya digunakan untuk obat perut kembung, sembelit, dan mual.
17		Kasimbukan	Getah dan daun untuk obat bintik.	42		Sisih	Getah, daun, dan akarnya digunakan untuk obat <i>bebai (magic)</i> .
18		Kecubung	Bunga, akar, dan daun untuk obat guna-guna.	43		Srikaya	Serat kayunya digunakan untuk obat tidak enak badan.

19		Kelor	Daunnya digunakan untuk obat sakit mata.	44		Suren	Akar, daun, dan serat kayunya digunakan untuk obat bengkak dan koreng.
20		Keluak	Pucuk daun untuk obat mimisan.	45		Talas	Daunnya digunakan untuk obat demam dan insomnia.
21		Kembang Sepatu	Serat kayunya digunakan untuk pelancar persalinan.	46		Teleng	Daunnya digunakan untuk obat kejang.
22		Kepundung	Getahnya digunakan untuk obat bengkak pipi.	47		Terong Duri	Dibuat param yang digunakan untuk obat letih.
23		Ketimun Gantung	Daun dan akarnya digunakan untuk obat sakit saat keguguran.	48		Uyah Uyah	Daunnya digunakan untuk obat koreng kulit.
24		Kopi	Daunnya digunakan untuk obat hipertensi.	49		Wani	Getah dan daunnya untuk obat sakit telinga yang bernanah.

2.2 Preprocessing Data

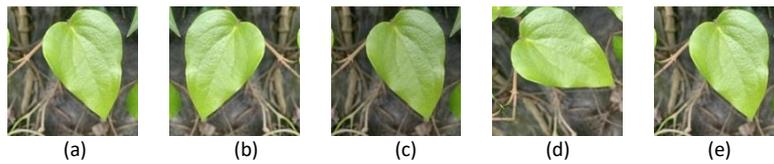
Tahap awal *preprocessing* data adalah *labelling* data atau memberi nama pada data gambar daun dalam setiap kelas. untuk mempermudah proses pelatihan model dalam mengenali dan membedakan objek atau fitur dalam gambar [20].

Setelah tahap *labelling* selesai, selanjutnya yakni proses augmentasi. Arsitektur CNN memerlukan jumlah data pelatihan yang besar, oleh karena itu teknik augmentasi diterapkan agar model dapat belajar dari gambar yang sama namun dengan perbedaan posisi dan kondisi, yang nantinya mampu membantu meningkatkan kinerja model dalam memprediksi gambar yang belum pernah dilihat sebelumnya [12]. Dalam penelitian ini, beberapa

teknik augmentasi yang digunakan dapat dijelaskan sebagai berikut.

- 1) Gambar diubah ukurannya menjadi 512x512 piksel untuk mempermudah komputasi.
- 2) Flip (horizontal flip)
- 3) Random Brightness Contrast, data citra akan teraugmentasi secara acak dengan limit brightness dan contrast yang digunakan antara -20 hingga 20.
- 4) Random rotate, data citra akan di putar dengan rentang maksimum antara 0 sampai 180 derajat secara acak.
- 5) Gauss Noise, data citra akan teraugmentasi dengan rentang maksimum variansi adalah 10% - 50%.

Saat metode augmentasi diterapkan pada 1000 gambar asli, jumlah gambar menjadi 5000, dengan 100 gambar untuk masing-masing kelas.



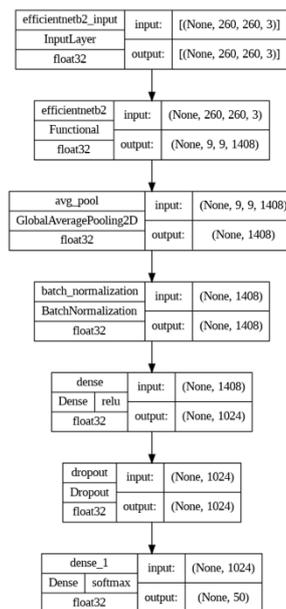
Gambar 2. Data Augmentasi dimulai dari *Resize* (a), *Horizontal Flip* (b), *Random Brightness Contrast* (c), *Random Rotate* (d), dan *Gauss Noise* (e)

2.3 Pembagian Data

Langkah terakhir sebelum memasuki tahap klasifikasi adalah membagi data menjadi data pelatihan, validasi, dan pengujian. Dimulai dengan membagi 80% dari dataset menjadi data untuk proses pelatihan, 60% untuk data training (3200 citra) dan 20% untuk validasi (800 citra), serta 20% untuk data pengujian (1000 citra). Setiap kelas memiliki 64 citra daun untuk data training, 16 gambar daun untuk data validasi, dan 20 gambar daun untuk data testing.

2.4 Pemodelan

Bagian ini akan berisi penjelasan mengenai pembangunan model yang dipergunakan sebagai *classifier*. Pada penelitian ini digunakan model pre-trained EfficientNet B2 yang telah dilatih sebelumnya dengan menggunakan bobot dari dataset ImageNet atau disebut dengan *Transfer Learning* [21]. Nantinya akan dilakukan *fine-tuning* parameter sebelum pelatihan model untuk meningkatkan akurasi dan kinerja model [22]. Susunan arsitektur EfficientNet B2 yang digunakan dalam penelitian ini adalah sebagai berikut.



Gambar 3. Susunan Arsitektur EfficientNet B2

Pada Gambar 3, usulan arsitektur EfficientNet B2 pada penelitian ini tersusun atas beberapa bagian dimulai dari gambar input dengan ukuran 260x260 piksel dengan 3 channel warna RGB. Lalu masuk pada lapisan utama dari EfficientNet B2. Fungsi ini mewakili arsitektur dari model yang relatif kompleks dan merupakan bagian utama dari jaringan. Hasil keluaran dari lapisan ini memiliki bentuk (*shape*)

dengan ukuran 9x9x1408. 9x9 menggambarkan dimensi spasial (*spatial dimensions*) dari keluaran, yaitu 9 baris dan 9 kolom. Angka 1408 menggambarkan jumlah fitur atau "*channel*" dalam keluaran. Selanjutnya adalah lapisan *Global Average Pooling* yang diikuti setelah lapisan utama EfficientNet B2. Lapisan ini mengubah output dari lapisan sebelumnya menjadi vektor dengan ukuran 1408, dengan

cara mengambil rata-rata dari semua nilai fitur di seluruh dimensi spasial. Hasil keluaran dari lapisan *Global Average Pooling* ini adalah vektor dengan ukuran 1408. Selanjutnya adalah lapisan *Batch Normalization*, lapisan ini dipergunakan untuk mempercepat dan meningkatkan stabilitas proses pelatihan [23]. Hasil keluaran dari lapisan *batch normalization* tetap memiliki ukuran 1408. Selanjutnya adalah lapisan *Dense* yakni lapisan *fully connected* dengan 1024 neuron. Lapisan ini melakukan operasi perkalian matriks antara input dengan bobot (weights) dan menambahkan bias untuk menghasilkan output. Setelahnya, ditambahkan lapisan *dropout* sebesar 20%, Lapisan ini digunakan untuk menghindari *overfitting* dengan secara acak menghapus beberapa neuron selama pelatihan. Hasil keluaran dari lapisan *dropout* tetap memiliki ukuran 1024. Terakhir, adalah lapisan *dense* kedua (*fully connected*) dengan 50 neuron. Lapisan ini bertindak sebagai lapisan keluaran yang menghasilkan prediksi akhir berupa vektor dengan ukuran 50, yang sesuai dengan jumlah kelas yang akan diprediksi.

Diperlukan penentuan nilai-nilai *hyperparameter* seperti *loss function*, *optimization function*, *epoch*, *early stopping*, dan metrik pengujian yang akan digunakan sebelum memulai proses training.

Selama proses training berlangsung, model belajar dari seluruh data dari jumlah epoch yang telah ditetapkan, yaitu 200 epoch. Dengan menggunakan *early stopping*, model tidak perlu menempuh keseluruhan epoch agar mencapai kondisi konvergen. Jadi proses training akan langsung berhenti jika tidak ada penurunan nilai *validation loss*. Dalam hal ini, parameter *patience* dengan nilai 10 digunakan untuk menentukan batas epoch selanjutnya jika tidak ada penurunan nilai *validation loss*. *Early stopping* umum digunakan sebagai penghemat penggunaan komputasi atau sumber daya.

Rincian parameter yang digunakan pada penelitian ini adalah sebagai berikut.

Tabel 2: Rincian Parameter

<i>Parameter</i>	<i>Value</i>
<i>Epoch</i>	Max 200
<i>Learning Rate</i>	1x10 ⁻³
<i>Optimizer</i>	Adam
<i>Loss Function</i>	Categorical Cross Entrophy
<i>Dropout</i>	20%
<i>Weight</i>	ImageNet
<i>Early Stop</i>	Patience = 10

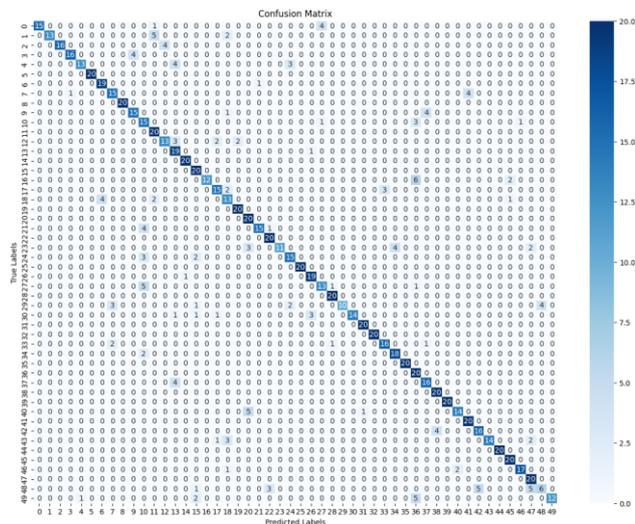
3. HASIL DAN PEMBAHASAN

Percobaan untuk penelitian ini dilakukan pada *Google Colaboratory* menggunakan *library Keras (Python Deep Learning library)* dengan sebuah layanan GPU. Pada Gambar 4 dibawah ini menampilkan hasil dari akurasi proses training dan testing menggunakan EfficientNet B2, dengan *learning rate* 1x10⁻³ untuk maksimal 200 epoch.



Gambar 4. Hasil Akurasi Training, Validation, dan Testing menggunakan EfficientNet B2

Berdasarkan hasil akurasi proses training dan testing diatas, akurasi terbaik menggunakan arsitektur EfficientNet B2 adalah 97,5% untuk data training, 81,77% untuk data validation, dan 83,49% untuk data testing dimana proses training berhenti pada epoch ke-14. Berikut merupakan confusion matrix dari data testing untuk evaluasi performa model.



Gambar 5. Confusion Matrix untuk Data Testing

Berdasarkan confusion matrix di atas, peringkat 5 tertinggi jenis citra daun yang dapat di prediksi dengan benar secara keseluruhan (20 data testing per kelas) adalah kelas Ceremai, Gadung, Jarak Pagar, Juwet, dan Kaca Piring. Sedangkan peringkat 5 terbawah hasil dari prediksi adalah kelas Uyah Uyah (prediksi benar berjumlah 6 dari 20 citra), Mengkudu (prediksi benar berjumlah 10 dari 20 citra), Ketimun Gantung (prediksi benar berjumlah 11 dari 20 citra), Kamboja (prediksi benar berjumlah 12 dari 20 citra), dan Wani (prediksi benar berjumlah 12 dari 20 citra) karena bentuknya yang sangat mirip.

Penelitian ini juga mengambil nilai metrik *precision*, *recall*, dan *F1-Score* untuk mengevaluasi performansi dari model. Ketiga parameter metrics tersebut digunakan untuk mendeteksi tingkat bias serta mengetahui keseimbangan kinerja model dalam pengklasifikasian data. Pada Tabel 3 berikut merupakan hasil nilai evaluasi model berdasarkan parameter metrik yang digunakan.

Tabel 3: Nilai Evaluasi Performa Model

Parameter	Value
Accuracy	83,49%
Precision	86%
Recall	83,49%
F-1 Score	83,49%

4. KESIMPULAN

Penelitian ini menyimpulkan bahwa telah dibuat dataset citra daun tumbuhan herbal berdasarkan Lontar Usada Taru Pramana yang dinamakan TPHerbleaf, meliputi 50 kelas citra daun tumbuhan herbal. Hasil klasifikasi menggunakan dataset TPHerbleaf dengan model pre-trained EfficientNet B2 menunjukkan bahwa berdasarkan hasil pengukuran secara keseluruhan pada metrik *precision*, *recall*, dan *F1-score* pada data *testing*, dataset ini punya representasi yang baik dalam keseimbangan data. Pada metode EfficientNet B2 menghasilkan akurasi sebesar 83,49%, beberapa pengembangan yang dapat dilakukan dapat berupa *tunning* parameter seperti penyesuaian *epoch*, *learning rate*, penggunaan parameter lain dari *optimizer*, atau bisa juga dengan menambah dan mengatur ulang nilai pada layer yang dibutuhkan pada arsitektur berupa layer *dropout* ataupun *batch normalization*.

Penelitian selanjutnya juga diharapkan dapat melakukan eksplorasi ke wilayah lain guna memperkaya dataset TPHerbleaf dengan tetap berpedoman pada Lontar Usada Taru Pramana, serta dapat menghubungi author apabila akan menggunakan atau mengembangkannya.

PERNYATAAN PENGHARGAAN

Penelitian ini didanai oleh DIKTI Penelitian dan Pengabdian kepada Masyarakat pada Penelitian Tesis Magister (PTM) Program Pendanaan Penelitian tahun 2023.

DAFTAR PUSTAKA

- [1] R. Akter and M. I. Hosen, "CNN-based Leaf Image Classification for Bangladeshi Medicinal Plant Recognition," in *2020 Emerging Technology in Computing, Communication and Electronics (ETCCE)*, 2020, pp. 1–6, doi: 10.1109/ETCCE51779.2020.9350900.
- [2] K. E. Tarigan and M. Stevani, "Ecology of The Batak Toba Medicinal Plants in Praxis Social Approach," *Br. J. Biol. Stud.*, vol. 1, no. 1, pp. 42–48, 2021, doi: 10.32996/bjbs.2021.1.1.3.
- [3] B. D. Mardiana, W. B. Utomo, and U. N. Oktaviana, "Herbal Leaves Classification Based on Leaf Image Using CNN Architecture Model VGG16," *J. Resti Rekayasa Sist. dan Teknol ogi Inf.*, vol. 7, no. 1, pp. 20–26, 2023, [Online]. Available: <https://jurnal.iaii.or.id/index.php/RESTI/article/view/4550/695>.
- [4] I Wayan Sukersa, *Usada Taru Pramana: Sebuah Wahana Pelestarian Flora Bahan Obat Tradisional Bali*. Denpasar: Swasta Nulus, 2017.
- [5] P. E. S. Adnyana, "Empirisme Penggunaan Tumbuhan pada Pengobatan Tradisional Bali : Lontar Taru Pramana dalam Konstruksi Filsafat Ilmu," *SANJIWANI J. Filsafat*, vol. 12, no. 1, 2021, [Online]. Available: <http://ejournal.ihdn.ac.id/index.php/Sanjwani/article/view/2059/1631>.
- [6] Y. Zhang, J. Cui, Z. Wang, J. Kang, and Y. Min, "Leaf Image Recognition Based on Bag of Features," *MDPI*, 2020, doi: 10.3390/app10155177.
- [7] M. F. Kazerouni, N. T. M. Saeed, and K.-D. Kuhnert, "Fully-automatic natural plant recognition system using deep neural network for dynamic outdoor environments," *Springer Nat. Switz. AG 2019*, vol. 1, no. 756, 2019, doi: 10.1007/s42452-019-0785-9.
- [8] C. P. Lee, K. M. Lim, Y. X. Song, and A. Alqahtani, "Plant-CNN-ViT: Plant Classification with Ensemble of Convolutional Neural Networks and Vision Transformer," *Plants (Basel)*, vol. 12, no. 14, p. 2642, 2023, doi: 10.3390/plants12142642.
- [9] S. A. Wagle, R. Harikrishnan, S. H. M. Ali, and Mohammad Faseehuddin, "Classification of Plant Leaves Using New Compact Convolutional Neural Network Models," *Plants*, vol. 11, no. 1, p. 24, 2021, doi: 10.3390/plants11010024.
- [10] I. W. Y. Dharma and I. G. A. R. Jayawangsa, "LONTAR TARU PREMANA WARISAN JENIUS LOKAL BALI KAJIAN ETNOPEADADOGI," *Subasita J. Sastra Agama dan Pendidik. Bhs. Bali*, vol. 1, no. 2, pp. 1–12, 2020, [Online]. Available: <https://ojs.unud.ac.id/index.php/kajianbali/article/view/48822>.
- [11] B. M. Quach, D. V. Cuong, N. Pham, D. Huynh, and B. T. Nguyen, *An Effective Leaf Recognition Using Convolutional Neural Networks Based Features*. 2021.
- [12] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *J. Big Data*, vol. 6, no. 60, pp. 1–48, 2019, doi: 10.1186/s40537-019-0197-0.
- [13] R. Kumar, A. Chug, A. P. Singh, and D. Singh, "A Systematic Analysis of Machine Learning and Deep Learning Based Approaches for Plant Leaf Disease Classification: A Review," *J. SensorsHindawi*, vol. 2022, pp. 1–13, 2022, doi: <https://doi.org/10.1155/2022/3287561>.
- [14] Felix, J. Wijaya, S. P. Sutra, P. W. Kosasih, and P. Sirait, "Implementasi Convolutional Neural Network Untuk Identifikasi Jenis Tanaman Melalui Daun," *J. SIFO Mikroskil*, vol. 21, no. 1, pp. 1–10, 2020, [Online]. Available: <https://www.mikroskil.ac.id/ejurnal/index.php/jsm/article/view/672>.
- [15] K. Sreenath P *et al.*, "Deep Learning Classification of Lake Zooplankton," *Front. Microbiol.*, vol. 12, 2021, doi: 10.3389/fmicb.2021.746297.
- [16] S. Aras, A. Setyanto, and Rismayani, "Deep Learning Untuk Klasifikasi Motif Batik Papua Menggunakan EfficientNet dan Transfer Learning," *Insect (Informatics Secur. J. Tek. Inform.)*, vol. 8, no. 1, pp. 11–20, 2022, doi: 10.33506/insect.v8i1.1865.
- [17] Sutomo and R. Iryadi, "Konservasi Tumbuhan Obat Tradisional 'Usada

- Bali,” *Bul. Udayana Mengabdi*, vol. 18, no. 4, pp. 58–63, 2019, doi: 10.24843/BUM.2019.v18.i04.p11.
- [18] H. A. Pitoyo, “IMPLEMENTASI METODE SUPPORT VECTOR MACHINE UNTUK KLASIFIKASI DAUN MANGGA BERDASARKAN TEKSTUR DAUN,” Universitas Islam Negeri Syarif Hidayatullah Jakarta, 2020.
- [19] Rosalina and A. Wijaya, “Pendeteksian Penyakit pada Daun Cabai dengan Menggunakan Metode Deep Learning,” *JuTISI J. Tek. Inform. dan Sist. Inf.*, vol. 6, no. 3, pp. 452–461, 2020, [Online]. Available: <https://journal.maranatha.edu/index.php/jutisi/article/view/2857>.
- [20] Y. Arun and V. G. S, “Leaf Classification for Plant Recognition using EfficientNet Architecture,” *Int. J. Eng. Res. Technol.*, vol. 10, no. 11, pp. 68–72, 2021, [Online]. Available: <https://www.ijert.org/leaf-classification-for-plant-recognition-using-efficientnet-architecture>.
- [21] M. Tan and Q. V. Le, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks,” *arXiv:1905.11946*, 2019, doi: 10.48550/arXiv.1905.11946.
- [22] I. Syurfi, “PENERAPAN DEEP LEARNING DENGAN CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI CITRA DIABETIC DENGAN ARSITEKTUR EFFICIENTNET-B7,” UNIVERSITAS ISLAM NEGERI SULTAN SYARIF KASIM, 2021.
- [23] J. Bjorck, C. Gomes, B. Selman, and K. Q. Weinberger, “Understanding Batch Normalization,” 2018, doi: 10.48550/arXiv.1806.02375.