

Klasifikasi Jenis Daun Tumbuhan Herbal Berdasarkan Lontar Usada Taru Pramana Menggunakan CNN

Classification of Herbal Plant Leaf Types Based on Lontar Usada Taru Pramana Using CNN

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
⁵Program Studi Rekayasa Sistem Komputer, Institut Bisnis dan Teknologi Indonesia
E-mail: ¹dita.ariani.sukma@undiksa.ac.id, ²antara.kesiman@undiksa.ac.id, ³sunarya@undiksha.ac.id, ⁴indradewi@undiksha.ac.id, ⁵gdandika@instiki.ac.id

Abstrak

Lontar Usada Taru Pramana adalah manuskrip yang merupakan kearifan lokal Bali yang berisi mengenai pengobatan tradisional dengan tumbuhan herbal serta telah dikaji secara ilmiah. Tumbuhan herbal umumnya dikenali dari daunnya. Namun, pengenalan tumbuhan herbal menjadi sulit karena minimnya pengetahuan mengenai jenis tumbuhan herbal dan kemiripan morfologi daunnya. Penelitian ini menggunakan dataset citra daun tumbuhan herbal bernama *TPHerbleaf* yang digunakan untuk mengklasifikasikan jenis daun tumbuhan herbal berdasarkan *Lontar Usada Taru Pramana*. Dataset ini terdiri dari 50 kelas jenis daun tumbuhan herbal. Penelitian ini menggunakan tiga arsitektur *Convolutional Neural Network* sebagai perbandingan untuk klasifikasi, yaitu *MobileNet*, *Inception ResNet V2*, dan *EfficientNet B2*. Model dengan hasil terbaik adalah *MobileNet* dengan *learning rate* 0,0001 dan *dropout* 20%. Model ini menghasilkan akurasi 100% untuk proses *training*, 79% untuk *validation*, dan 82% untuk *testing*. Hasil penelitian ini menunjukkan bahwa teknologi modern dapat digunakan untuk meningkatkan pemahaman dan pelestarian warisan budaya melalui penerapan praktik dalam bidang klasifikasi citra.

Kata kunci: Tumbuhan Herbal, Lontar Usada Taru Pramana, Klasifikasi, CNN

Abstract

Lontar Usada Taru Pramana is a manuscript that is Balinese local wisdom that contains traditional medicine with herbal plants and has been studied scientifically. Herbal plants are commonly recognized by their leaves. However, the classification of herbal plants becomes difficult due to the lack of knowledge about the types of herbal plants and the morphological similarities of their leaves. This study used a dataset of leaf images of herbal plants named *TPHerbleaf* which used to classify the types of leaves of herbal plants based on *Lontar Usada Taru Pramana*. This dataset consists of 50 classes of leaf species of herbal plants. This study uses three *Convolutional Neural Network* architectures as a comparison for classification, namely *MobileNet*, *Inception ResNet V2*, and *EfficientNet B2*. The model with the best results is *MobileNet* with a *learning rate* of 0.0001 and a *dropout* of 20%. This model produces 100% accuracy for the training process, 79% for validation, and 82% for testing. The results of this study shows that modern technology can be used to improve the understanding and preservation of cultural heritage through the application of practices in the field of image classification.

Keywords: Herbal Plants, Lontar Usada Taru Pramana, Classification, CNN

1. PENDAHULUAN

Tumbuhan merupakan salah satu komponen esensial serta memberikan kontribusi yang signifikan dalam ekosistem makhluk hidup. Tumbuhan tidak hanya berperan penting sebagai

penghasil oksigen dan bahan baku makanan serta industri, namun tumbuhan juga merupakan sumber daya yang berharga dalam bidang kesehatan manusia. Adapun jenis-jenis tumbuhan yang digunakan secara khusus dipergunakan sebagai pengobatan dalam bidang kesehatan umumnya disebut sebagai tumbuhan herbal [1]. Ada sekitar 40.000 spesies tumbuhan herbal yang telah dikenal di dunia, dan sekitar 30.000 spesies berada di Indonesia [2]. Dikarenakan semakin mahalnya harga dari obat-obatan kimia serta efek samping yang ditimbulkan menyebabkan penggunaan obat tradisional kembali meningkat [3].

Adapaun terdapat sekitar 80% masyarakat masih bergantung pada tumbuhan herbal untuk kesehatan [4]. *Lontar Usada Taru Pramana* merupakan sebuah contoh nyata kearifan budaya lokal Bali yang didalamnya memuat catatan mengenai jenis-jenis tumbuhan herbal dan penggunaan tumbuhan herbal sebagai pengobatan tradisional dimana sebelumnya telah dikaji secara ilmiah dan masih digunakan oleh sebagian besar masyarakat Bali hingga saat ini sebagai pedoman penggunaan tumbuhan herbal [5] [6].

Terdapat sekitar 180 jenis tumbuhan herbal yang dapat digunakan sebagai pengobatan tradisional dalam *Lontar Usada Taru Pramana* [7]. Seiring dengan jumlah spesies tumbuhan herbal yang begitu banyak serta beragam, proses klasifikasi tumbuhan herbal tentunya menjadi tugas yang kompleks dan membutuhkan waktu yang relatif lama. Disamping hal tersebut, pada proses klasifikasi ini ditemukan tantangan konvensional yang cukup rumit. Selain keterbatasan pengetahuan botani yang dimiliki, tumbuhan-tumbuhan herbal juga sulit diidentifikasi secara akurat, mengingat terdapat kesamaan dalam morfologi di antara beberapa spesies, sehingga sulit untuk dibedakan secara kasat mata. Kesalahan klasifikasi terkadang berdampak buruk apabila berhubungan dengan komposisi racikan tumbuhan herbal dengan tujuan pengobatan [4]. Berkenaan dengan permasalahan tersebut, diperlukan adanya pengembangan sebuah sistem klasifikasi tumbuhan herbal secara otomatis. Tujuan dari adanya pengembangan sistem ini yakni untuk mempermudah manusia dalam mengenali jenis-jenis tanaman herbal dengan akurat dan dalam waktu yang cepat. Diharapkan kedepannya bahkan orang-orang yang tidak paham betul mengenai botani pun akan mampu dengan mudah mengidentifikasi tumbuhan herbal. Oleh karena hal tersebut, adanya sistem klasifikasi otomatis merupakan hal yang krusial dalam mengatasi perbedaan atau kesenjangan pengetahuan dan menangani tantangan klasifikasi dalam upaya pelestarian serta pemanfaatan kekayaan alam dalam bentuk tumbuhan herbal.

Secara umum, bagian-bagian tumbuhan herbal yang dapat dipergunakan sebagai pengobatan dimulai dari batang, bunga, buah, serta daunnya. Dalam penelitian ini fokus utama bagian tumbuhan yang juga akan digunakan sebagai objek penelitian yakni daun, karena daun merupakan bagian tumbuhan yang paling stabil dalam periode hidup, bentuk, tekstur, serta paling mudah diakses dan paling tahan terhadap perubahan [8]. Dalam kasus klasifikasi tumbuhan herbal, dataset *Flavia* dan dataset *Swedish Leaf* adalah 2 dataset jenis tumbuhan herbal yang paling banyak digunakan, terdiri dari gambar laboratorium yang bersih tanpa latar belakang. Dataset tersebut juga digunakan dalam pelatihan arsitektur CNN untuk klasifikasi jenis tumbuhan. Model yang telah dilatih menggunakan dataset ini mendapatkan akurasi klasifikasi yang tinggi selama pelatihan. Namun, akurasi sistem ini menurun tajam dalam kinerjanya saat diuji dalam situasi nyata dikarenakan adanya perbedaan antara gambar laboratorium yang bersih tanpa latar belakang dan gambar yang dikumpulkan langsung di lapangan yang memiliki latar belakang yang kompleks, termasuk batang, buah, tanah, dan daun di sekitarnya [9][10]. Dataset tersebut memiliki kemungkinan yang tidak sepenuhnya dapat menangkap kompleksitas dan keberagaman gambar lapangan dunia nyata, sehingga menimbulkan tantangan dalam mengklasifikasikan tumbuhan herbal dengan akurat dalam lingkungan tersebut [9][11].

Mengatasi tantangan tersebut, pada penelitian menggunakan *TPHerbleaf* sebagai dataset untuk klasifikasi dengan 50 jenis daun tumbuhan herbal dengan 1000 citra daun berdasarkan *Lontar Usada Taru Pramana* [12]. *Lontar Usada Taru Pramana* memuat ilmu pengobatan tradisional Bali mengenai ragam tumbuhan herbal dan khasiatnya, dimana sifat tanaman yang berbeda dan peluang penemuan baru dapat ditemukan [13]. Pengumpulan data dan informasi mengenai daun tumbuhan herbal yang berpedoman pada *Lontar Usada Taru Pramana* juga dapat membantu pelestarian warisan budaya Bali [13]. Dataset *TPHerbleaf* diharapkan dapat membantu

dalam peningkatan pengujian akurasi dari model usulan sebab citra daun yang telah dikumpulkan masih dalam kondisi sebenarnya saat di lapangan dengan *background natural*.

Data citra daun yang terdapat dalam dataset *TPHearbleaf* dikumpulkan dari beberapa wilayah di Bali yaitu Kabupaten Tabanan, Kabupaten Badung, dan Kota Denpasar. Tujuan dari pengumpulan data citra daun dari berbagai lokasi ini adalah untuk meningkatkan variasi citra daun dalam dataset sehingga sistem yang diusulkan dapat lebih akurat dan luas dalam mempelajari beragam bentuk, ukuran, dan warna daun dari setiap jenis karena variasi ini berbeda-beda di setiap lokasi [14]. Pengklasifikasian citra daun mempergunakan sampel data berdasarkan kesamaan fitur bentuk, warna, serta tekstur daun. Dalam proses klasifikasi, metode *machine learning* ataupun *deep learning* dapat dipergunakan. Salah satu penelitian [15] menjelaskan bahwa *machine learning* sulit untuk diterapkan dalam kondisi di dunia nyata, sedangkan *deep learning* terbukti lebih sesuai karena mampu mempelajari data dengan latar belakang yang lebih kompleks. Inilah yang mendasari pemilihan metode *deep learning* dalam penelitian ini untuk klasifikasi tumbuhan herbal dengan kondisi lapangan.

Salah satu metode *deep learning* yang dirancang untuk memproses data dalam bentuk gambar dan sering digunakan pada kasus klasifikasi gambar ialah *Convolutional Neural Network* (CNN) [4]. Namun, CNN membutuhkan jumlah data yang besar dalam proses klasifikasi. Untuk itu dalam proses memperkaya data, beragam teknik augmentasi telah diterapkan pada penelitian ini sehingga 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 [16].

Berdasarkan beberapa penelitian terdahulu, seperti yang disajikan pada penelitian oleh [17] dan [18] mengenai klasifikasi daun tumbuhan herbal diperoleh nilai akurasi klasifikasi sebesar 71.3% dan 76%. *Convolutional Neural Network* adalah metode yang diakui sebagai metode terbaik untuk pemecahan masalah klasifikasi, deteksi dan pengenalan objek [19]. Pada metode *Convolutional Neural Network* terdapat beberapa macam arsitektur yang umum dipergunakan pada pemecahan masalah klasifikasi objek.

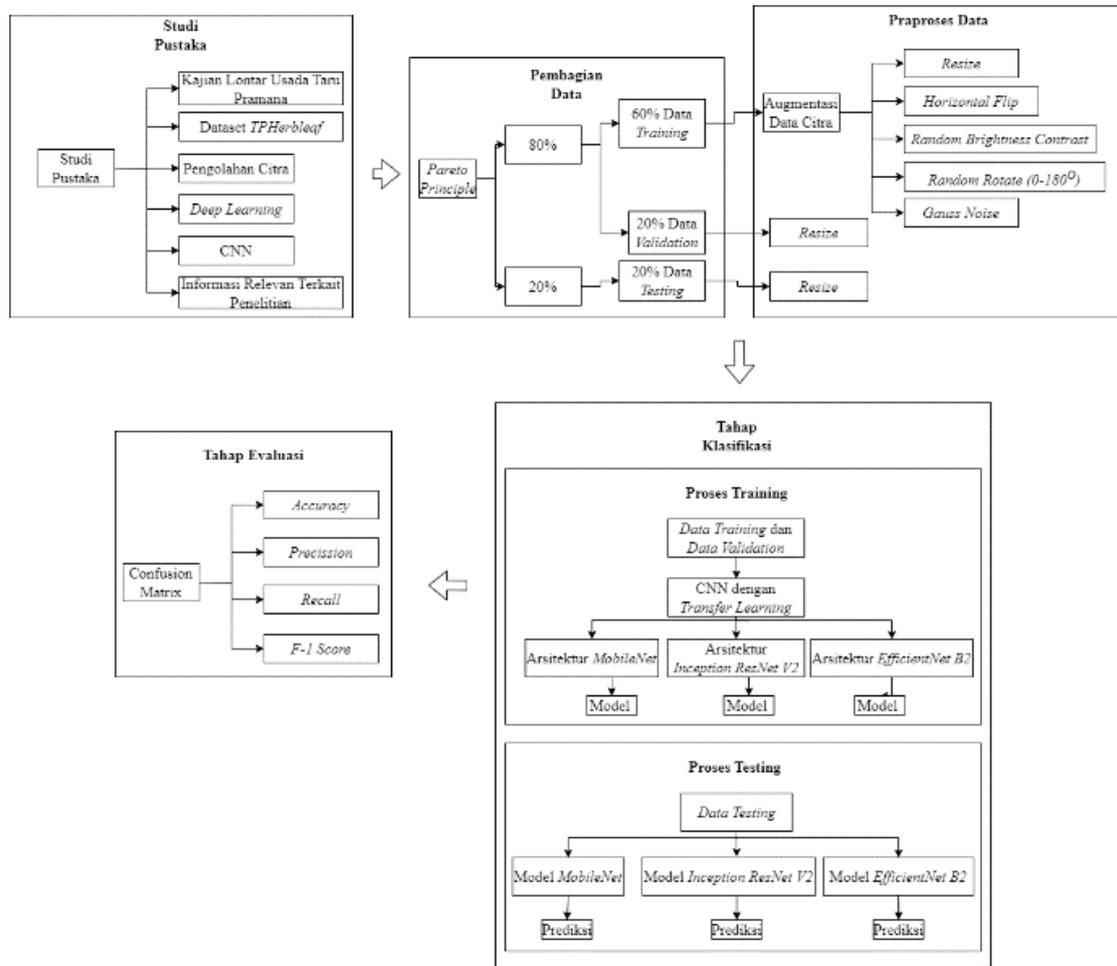
Selanjutnya, adapun penelitian oleh [20] yang mengimplementasikan CNN dengan 2 arsitektur sebagai perbandingan yakni *MobileNet* dan *VGG16* untuk mengklasifikasikan 5 jenis kayu yaitu *Akasia*, *Balau*, *Nangka*, *Jati* dan *Sengon*. Arsitektur *MobileNet* memiliki hasil akurasi yang lebih baik senilai 96% dibandingkan *VGG16* dengan akurasi 90%. Selain lebih baik dari segi akurasi, *MobileNet* juga menyelesaikan proses pelatihan lebih cepat dan memiliki *size* model lebih kecil.

Penelitian oleh [21] menerapkan metode CNN dengan arsitektur *Inception ResNet V2* untuk mengklasifikasikan diagnosa *image Chest XRay* hasil dari *CT Scan* yang terdiri dari 4 kelas. Hasil uji memiliki akurasi 98%. Selain itu, pada penelitian ini juga mencakup perbandingan nilai akurasi *Inception Resnet V2* dengan versi terdahulunya yakni dengan *Inception V3*, *ResNet 152*, dan *ResNet V2 200*. Arsitektur *Inception Resnet V2* menghasilkan perfromansi paling optimal dibanding dengan versi terdahulunya, melalui peningkatan komputasi dengan cara penguraian *convolution matrix* besar menjadi berukuran lebih kecil.

Penelitian selanjutnya [22] mengimplementasikan CNN dengan teknik *transfer learning* dengan beberapa arsitektur yakni *EfficientNet B0-B7*, *InceptionV3*, *DenseNet121*, *MobileNet*, dan *ResNet50* untuk klasifikasi objek. Model dengan *F-1 Score* terbaik adalah *EfficientNet B2* serta tercantum penjelasan bahwa *EfficientNet B2* memberikan keseimbangan yang menguntungkan antara kinerja dan ukuran model. Teknik *transfer learning* juga dibuktikan pada penelitian ini dapat mempercepat proses pelatihan dan menghasilkan model yang lebih baik dalam kinerjanya. Dari beberapa studi literatur mengenai arsitektur CNN tersebut, 3 diantaranya yakni *MobileNet*, *Inception ResNet V2*, dan *EfficientNet B2* memiliki akurasi dan efisiensi yang cukup baik.

Pada penelitian ini, akan dirancang dan dibangun sebuah program yang dapat mengenali suatu objek citra daun tumbuhan herbal mempergunakan metode CNN dengan 3 arsitektur usulan yakni *MobileNet*, *Inception ResNet V2*, dan *EfficientNet B2* serta akan dipilih arsitektur terbaik dalam mengklasifikasikan jenis daun tumbuhan herbal.

2. METODE PENELITIAN



Gambar 1 Alur Penelitian

Pada Gambar 1 diatas adalah bagan alur yang memuat rincian kerja atau langkah penelitian dari awal hingga pada hasil dari penelitian. Tahapan yang ada pada penelitian ini dimulai dari studi pustaka, pembagian data, praproses data dan tahap akhir adalah tahap klasifikasi dan evaluasi.

2.1 Studi Pustaka

Studi Pustaka dalam penelitian ini dibagi menjadi tiga bagian khusus, yakni studi pustaka mengenai kajian *Lontar Usada Taru Pramana*, studi pustaka dataset, serta studi pustaka mengenai penelitian terdahulu yang berkaitan dengan penelitian ini. Pada penelitian oleh [12], telah dijabarkan secara rinci mengenai studi pustaka kajian *Lontar Usada Taru Pramana* yang digunakan sebagai acuan atau pedoman pengumpulan data, yakni dimulai dari kajian *Lontar Usada Taru Pramana* oleh I Wayan Sukersa tahun 2017 [5], Sutomo dan Rajif I. tahun 2019 [23], dan Putu Eka Sura Adnyana tahun 2021 [7]. 50 jenis tumbuhan herbal telah dikumpulkan dari literatur tersebut dan selanjutnya dipergunakan sebagai kelas citra daun dalam dataset *TPHerbelaf* [12], antara lain *Ancak, Awar-awar, Beringin, Cemara, Cempaka Kuning, Ceremai, Dapdap, Delima, Gadung, Jambu Air, Jambu Biji, Jarak Pagar, Jeruk Limau, Jeruk Sitrun, Juwet, Kaca Piring, Kamboja, Kasimbukan, Kecubung, Kelor, Keluak, Kembang Sepatu, Kepundung, Ketimun Gantung, Kopi, Lantana, Legundi, Mangga Amplem, Manggis, Mengkudu, Merica, Nanas, Pakis Sayur, Pala, Pare, Pepaya, Pule, Salam, Semanggi, Sembung, Sirih, Sirsak, Sisih, Srikaya, Suren, Talas, Teleng, Terong Duri, Uyah-uyah, dan Wani*. Dataset dapat diakses pada *link google drive*

yang terlampir berikut : (<https://drive.google.com/drive/folders/1XSZQ0G0NpBummjTAD-oYwdjDL1MrO-jd?usp=sharing>). Daun dan bagian lain dari masing-masing tumbuhan herbal mampu dipergunakan sebagai pengobatan berbagai jenis penyakit, dimulai dari penyakit ringan seperti demam, insomnia, mual dan sebagainya [5]. Penjelasan mengenai khasiat tanaman herbal tertuang lengkap dalam 3 literatur yang telah disebutkan mengenai kajian *Lontar Usada Taru Pramana*.

Data citra asli pada dataset *TPHerbleaf* berjumlah 1000 *raw images* dari berbagai jenis daun, dengan masing-masing 20 gambar pada setiap kelas [12].

2.2 Pembagian (Splitting) Data

Langkah selanjutnya setelah studi pustaka ialah pembagian atau *splitting* data menjadi data *training*, data *validation*, dan data *testing*. *Training set* digunakan untuk melatih model dan membantunya menemukan fitur dan pola tersembunyi dalam data, *validation set* digunakan untuk menilai model selama pelatihan dan menghindari *overfitting*, serta *testing set* digunakan untuk menguji model setelah menyelesaikan pelatihan dan menilai seberapa baik kinerjanya pada data yang tidak diketahui [24]. 1000 citra daun pada dataset *TPHerbleaf* dibagi menjadi 60% untuk data *training* (600 citra), 20% data *validation* (200 citra), dan 20% data *testing* (200 citra). Masing-masing kelas memiliki 12 citra daun pada data *training*, 4 citra daun pada data *validation*, dan 4 citra daun pada data *testing* dengan masing-masing 50 kelas sesuai dengan *Pareto Principle* [25]. Pada dataset *TPHerbleaf* sebelumnya telah dilakukan *data labelling* atau pemberian label nama pada data citra, sehingga tidak perlu dilakukan *data labelling* ulang pada penelitian ini.

2.3 Praproses Data

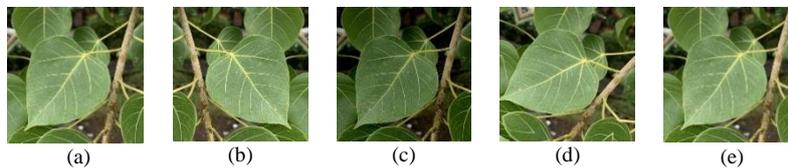
Setelah pembagian data selesai dilakukan, langkah selanjutnya adalah proses augmentasi. Teknik augmentasi yang diterapkan dalam penelitian ini membantu model dapat belajar dari gambar yang sama namun dengan arah dan kondisi yang berbeda dan meningkatkan performa model dalam memprediksi gambar yang belum pernah terlihat sebelumnya [16]. Teknik augmentasi yang dilakukan dalam penelitian ini adalah *Resizing* citra menjadi ukuran 512x512 piksel, *Flip (horizontal flip)*, *Random Brightness Contrast*, *Random Rotate*, dan *Gauss Noise* [26].

Teknik augmentasi hanya dilakukan pada 600 citra asli dalam data *training* (12 citra di setiap kelas), sehingga jumlah citra dalam data *training* meningkat menjadi 3000 citra dengan 60 citra di setiap kelas, sedangkan data *validation* dan *testing* hanya dilakukan *resize* menjadi 512x512 piksel. Hal ini bertujuan agar data *validation* dan data *testing* memiliki karakteristik yang sama dengan data asli, sehingga dapat digunakan untuk mengevaluasi performa model secara akurat. Jumlah citra dalam data *validation* dan data *testing* masing-masing masih 200 gambar (4 gambar di setiap kelas). Pada Gambar 2 berikut merupakan *sample* citra dari masing

masing kelas daun yang digunakan dalam penelitian, dan pada Gambar 3 merupakan penerapan dari teknik augmentasi yang diusulkan.



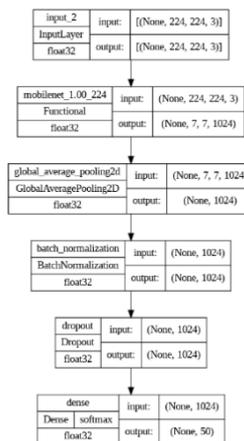
Gambar 2 Citra Daun dalam Dataset TPHerbleaf



Gambar 3 Seluruh teknik augmentasi yakni *Resize* (a), *Horizontal Flip* (b), *Random Brightness Contrast* (c), *Random Rotate* (d), dan *Gauss Noise* (e)

2.3 Pemodelan

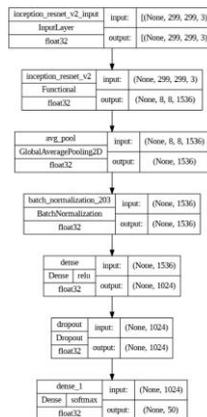
Sub-bab ini memuat rincian mengenai struktur model yang dipergunakan dalam proses klasifikasi. Dalam penelitian ini diusulkan model *pre-trained MobileNet*, *Inception ResNet V2*, serta *EfficientNet B2* dimana arsitektur-arsitektur CNN usulan menggunakan teknik *transfer learning*, yang merupakan model yang sebelumnya telah dilatih dengan menggunakan bobot dari dataset lain seperti *ImageNet* [27]. Telah dilakukan *hyperparameter tuning* sebelum pelatihan model untuk meningkatkan akurasi dan kinerja model [28]. Struktur model dari ketiga arsitektur usulan adalah sebagai berikut.



Gambar 4. Arsitektur *MobileNet* Usulan

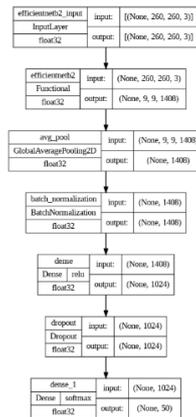
Sesuai dengan Gambar 4, usulan arsitektur *MobileNet* dalam penelitian ini tersusun atas beberapa bagian. Diawali dengan gambar masukan (citra *input*) berukuran 224x224 piksel dengan tiga saluran warna (*channel*) RGB. Kemudian, masuk pada bagian inti *MobileNet* yakni (*MobileNet 1.00 224*) yang merupakan bagian *MobileNet* terlatih (*pre-trained model*) untuk

mengambil fitur gambar. Bagian ini bertindak sebagai *feature extractor* dan menghasilkan *output* berupa fitur-fitur berukuran 7×7 dengan 1024 saluran. Selanjutnya adalah *Global Average Pooling* yang diikuti setelah bagian utama *MobileNet*. *Global Average Pooling* mengubah *output* akhir dari *layer* sebelumnya menjadi vektor berukuran 1024, dengan merata-ratakan nilai fitur di seluruh unit spasial dan mengubah keluaran *layer* sebelumnya menjadi vektor berukuran 1024. *Output* dari *Global Average Pooling* ini adalah vektor dengan ukuran 1024. Selanjutnya adalah *Batch Normalization*, yang dipergunakan untuk mempercepat proses pelatihan dan meningkatkan stabilitas [29]. *Output* dari *Batch Normalization* tetap berukuran 1024. Setelahnya, ditambahkan *layer Dropout*, yang dipergunakan untuk menghindari *overfitting* dengan cara menghapus beberapa neuron secara acak selama proses pelatihan. Hasil keluaran dari *layer Dropout* tetap berukuran 1024. Terakhir, adalah *layer Dense (Fully Connected)* dengan 50 neuron. *Layer* ini berperan sebagai *output layer* yang menghasilkan prediksi akhir berupa vektor dengan ukuran 50, sesuai dengan jumlah kelas yang akan diprediksi.



Gambar 5. Arsitektur *Inception ResNet V2* Usulan

Sesuai dengan Gambar 5, usulan arsitektur *Inception ResNet V2* dalam penelitian ini tersusun atas beberapa bagian. Diawali dengan gambar masukan (citra *input*) berukuran 299×299 piksel dengan tiga saluran warna (*channel*) RGB. Kemudian, masuk pada bagian inti dari *Inception Resnet V2* yakni *inception_resnet_v2*. Bagian ini mewakili arsitektur dari model yang relatif kompleks dan merupakan bagian utama dari jaringan. *Output* pada bagian ini memiliki bentuk (*shape*) $8 \times 8 \times 1536$. 8×8 menggambarkan dimensi spasial (*spatial dimensions*) dari *output*, yaitu 8 baris dan 8 kolom. Angka 1536 menggambarkan jumlah fitur atau *channel* dalam *output*. Selanjutnya adalah *Global Average Pooling*, *output* dari *Global Average Pooling* berupa vektor berukuran 1536. Selanjutnya adalah *Batch Normalization*, dengan *output* berukuran 1536. Selanjutnya adalah *layer Dense* yakni *fully connected layer* dengan 1024 neuron. Kemudian, ditambahkan *Dropout*. *Output* dari *dropout* tetap memiliki ukuran 1024. Terakhir, adalah lapisan *Dense* kedua (*fully connected layer*) dengan 50 neuron yang berperan sebagai *output layer* yang menghasilkan prediksi akhir berupa vektor dengan ukuran 50.



Gambar 6. Arsitektur *EfficientNet B2* Usulan

Sesuai dengan Gambar 6, usulan arsitektur *EfficientNet B2* dalam penelitian ini tersusun atas beberapa bagian. Diawali dengan gambar masukan (citra *input*) berukuran 260x260 piksel dengan tiga saluran warna (*channel*) RGB. Kemudian, masuk pada bagian inti dari *EfficientNet B2* yakni *efficientnetb2*. Bagian ini mewakili arsitektur dari model yang relatif kompleks dan merupakan bagian utama dari jaringan. *Output* pada bagian ini memiliki bentuk (*shape*) 9x9x1408. 9x9 mewakili dimensi spasial (*spatial dimensions*) dari *output*, yaitu 9 baris dan 9 kolom. Angka 1408 menggambarkan jumlah fitur atau *channel* dalam *output*. Selanjutnya adalah *Global Average Pooling* dengan *output* berupa vektor berukuran 1408. Selanjutnya adalah *Batch Normalization*, dengan *output* berukuran 1408. Selanjutnya adalah layer *Dense* yakni *fully connected layer* dengan 1024 neuron. Kemudian, ditambahkan *Dropout* dengan *output* berukuran 1024. Terakhir, adalah lapisan *Dense* kedua (*fully connected layer*) dengan 50 neuron yang berperan sebagai *output layer* yang menghasilkan prediksi akhir berupa vektor dengan ukuran 50.

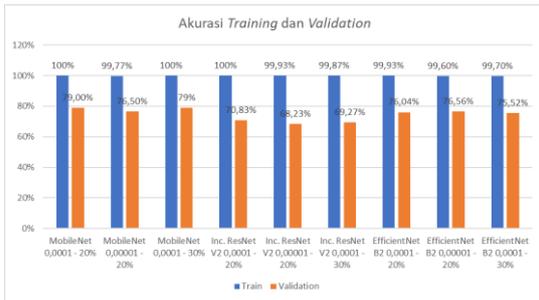
Terdapat penetapan nilai beberapa *hyperparameter* seperti *loss function*, *optimization function*, *epoch*, *early stopping*, dan metrik pengujian diperlukan sebelum memulai proses training. Rincian skenario pengujian dan parameter yang digunakan dalam penelitian ini adalah sebagai berikut.

Tabel 1 Rincian Skenario Pengujian dan Parameter

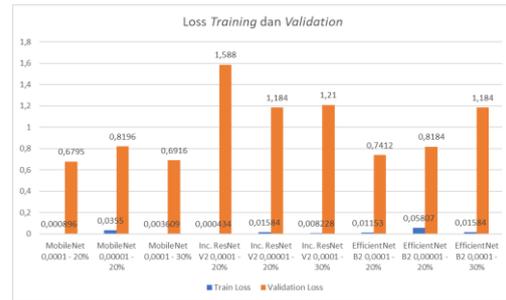
No	Arsitektur	Batch Size	Optimizer	Learning Rate	Dropout	Epoch
1	<i>MobileNet</i>	16	Adam	0,0001	20%	Max 100 epoch, patience=10
2	<i>MobileNet</i>	16	Adam	0,00001	20%	Max 100 epoch, patience=10
3	<i>MobileNet</i>	16	Adam	0,0001	30%	Max 100 epoch, patience=10
4	<i>Inception ResNet V2</i>	16	Adam	0,0001	20%	Max 100 epoch, patience=10
5	<i>Inception ResNet V2</i>	16	Adam	0,00001	20%	Max 100 epoch, patience=10
6	<i>Inception ResNet V2</i>	16	Adam	0,0001	30%	Max 100 epoch, patience=10
7	<i>EfficientNet B2</i>	16	Adam	0,0001	20%	Max 100 epoch, patience=10
8	<i>EfficientNet B2</i>	16	Adam	0,00001	20%	Max 100 epoch, patience=10
9	<i>EfficientNet B2</i>	16	Adam	0,0001	30%	Max 100 epoch, patience=10

3. HASIL DAN PEMBAHASAN

Eksperimen penelitian ini dilakukan pada *Google Colaboratory* menggunakan library *Keras (Python Deep Learning Library)* yang menggunakan layanan GPU. Ilustrasi hasil dari keseluruhan eksperimen dapat dilihat pada Gambar 7 dan Gambar 8, serta terdapat Tabel 2 yang menunjukkan rincian nilai akurasi dan nilai *loss* pada proses *training* dan *validation* dari ke-9 skenario pada 3 arsitektur usulan.



Gambar 7. Nilai Akurasi Training dan Validation Model Usulan

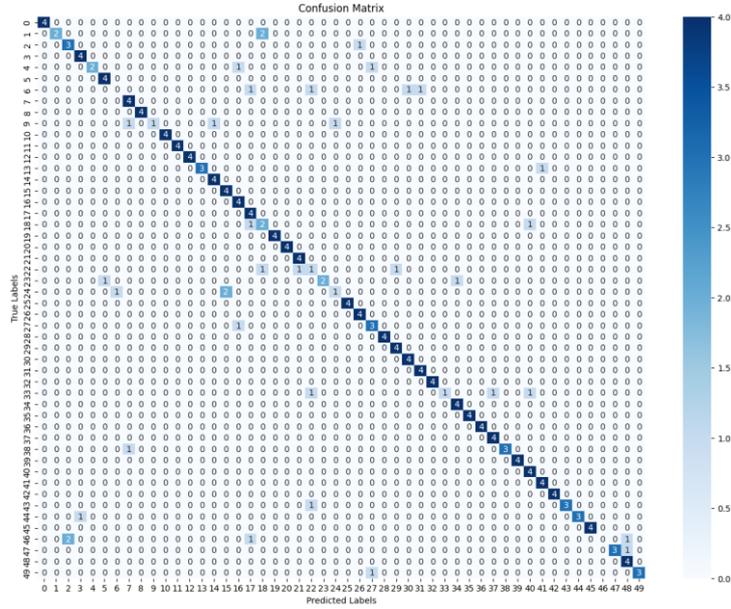


Gambar 8. Nilai Loss Training dan Validation Model Usulan

Tabel 2 Perbandingan Nilai Akurasi dan Loss Model Usulan

No	Arsitektur	Learning Rate	Dropout	Akurasi	Loss
1	MobileNet	1×10^{-4} atau 0,0001	20%	Train: 100% Validation: 79,00%	Train: 0,000896 Validation: 0,6795
2	MobileNet	1×10^{-5} atau 0,00001	20%	Train : 99,77% Validation: 76,50%	Train: 0,0355 Validation : 0,8196
3	MobileNet	1×10^{-4} atau 0,0001	30%	Train: 100% Validation: 79%	Train : 0,003609 Validation : 0,6916
4	Inception ResNet V2	1×10^{-4} atau 0,0001	20%	Train: 100% Validation : 70,83%	Train : 0,000434 Validation : 1,588
5	Inception ResNet V2	1×10^{-5} atau 0,00001	20%	Train : 99,93% Validation : 68,23%	Train : 0,01584 Validation : 1,184
6	Inception ResNet V2	1×10^{-4} atau 0,0001	30%	Train : 99,87% Validation : 69,27%	Train : 0,008228 Validation : 1,21
7	EfficientNet B2	1×10^{-4} atau 0,0001	20%	Train : 99,93% Validation : 76,04%	Train : 0,01153 Validation : 0,7412
8	EfficientNet B2	1×10^{-5} atau 0,00001	20%	Train : 99,60% Validation : 76,56%	Train : 0,05807 Validation : 0,8184
9	EfficientNet B2	1×10^{-4} atau 0,0001	30%	Train : 99,70% Validation : 75,52%	Train : 0,01584 Validation : 1,184

Berdasarkan nilai ke-9 eksperimen yang telah dilakukan, didapat hasil terbaik yakni model arsitektur *MobileNet* (Skenario 1) dengan *learning rate* 1×10^{-4} atau 0,0001 dan *dropout* 20%, dimana model tersebut memiliki nilai akurasi tertinggi sebesar 100% untuk proses *training* dan 79,00% untuk proses *validation*, serta nilai *loss* yang paling kecil diantara model lain yakni 0,000896 untuk proses *training* dan 0,6795 untuk proses *validation*. Setelah didapatkan model terbaik langkah berikutnya yakni evaluasi kinerja model dengan metrik *accuracy*, *precision*, *recall*, dan *f-1 score*. Nilai tersebut akan didapatkan dari *confusion matrix* pada Gambar 9.



Gambar 9. Confusion Matriks Model MobileNet Skenario 1

Berdasarkan confusion matriks diatas, terlebih dahulu menentukan nilai *total true positive*, *total false positive*, serta *total false negative* sebelum menghitung nilai metriks *accuracy*, *precision*, *recall*, dan *f-1 score*. Berikut merupakan rumus serta perhitungan metriks secara keseluruhan.

Total True Positive (TTP) : 164
 Total False Positive (TFP) : 36
 Total False Negative (TFN) : 36

$$\begin{aligned}
 \text{Total Accuracy} &= \frac{TTP_{all}}{\text{Total Number Of Testing Entries}} \times 100\% & (1) \\
 &= \frac{164}{200} \times 100\% \\
 &= 82\%
 \end{aligned}$$

$$\begin{aligned}
 \text{Average Precision} &= \frac{\sum Precision}{\text{Total Class}} \times 100\% & (2) \\
 &= \frac{41,05}{50} \times 100\% \\
 &= 82\%
 \end{aligned}$$

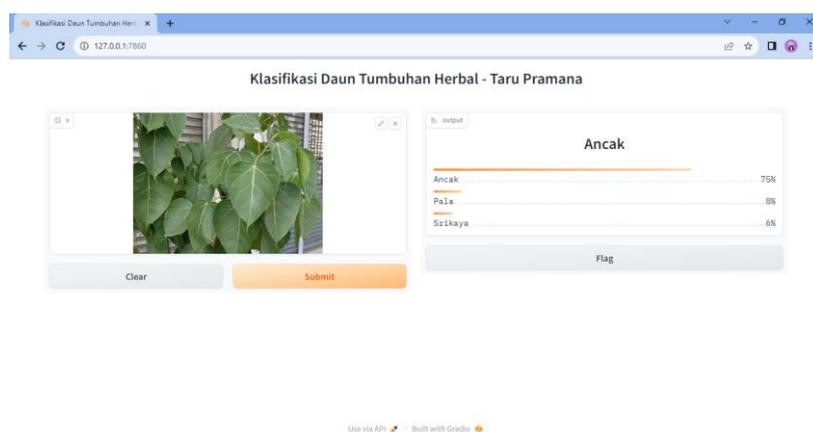
$$\begin{aligned}
 \text{Average Recall} &= \frac{\sum Recall}{\text{Total Class}} \times 100\% & (3) \\
 &= \frac{41}{50} \times 100\% \\
 &= 82\%
 \end{aligned}$$

$$\begin{aligned}
 F - 1 \text{ Score} &= \frac{2 (Precision \times Recall)}{Precision + Recall} \% & (4) \\
 &= \frac{2 \times (82 \times 82)}{(82 + 82)} \% \\
 &= 82\%
 \end{aligned}$$

Berdasarkan hasil evaluasi confusion matrix diatas, dapat disimpulkan bahwa model ini mempunyai kinerja yang baik. Secara spesifik, model mampu mengidentifikasi objek dengan benar sebanyak 82% (164 gambar) dari total 200 gambar, salah mendeteksi objek sebanyak 36 gambar, dan gagal mendeteksi objek sebanyak 36 gambar. Dari 36 gambar yang salah dideteksi,

36 gambar di antaranya merupakan objek yang seharusnya terdeteksi sebagai objek lain (*false positive*). Sedangkan dari 36 gambar yang gagal dideteksi, 36 gambar di antaranya merupakan objek yang seharusnya terdeteksi (*false negative*). Nilai *precision* model ini sebesar 82%, yang berarti bahwa model hanya memprediksi objek sebagai objek yang benar sebanyak 82% dari total objek yang diprediksi sebagai objek yang benar. Nilai *recall* model ini sebesar 82%, yang berarti bahwa model dapat mendeteksi sebanyak 82% dari total objek yang benar. Nilai *F1-score* model ini sebesar 82%, yang merupakan rerata harmonis dari *precision* dan *recall*. Nilai *F1-score* yang tinggi menunjukkan bahwa model memiliki performa yang baik dalam hal *precision* dan *recall*.

Model dengan akurasi terbaik disimpan dalam format .h5, untuk selanjutnya digunakan dalam pengujian dengan data baru, dimana akan dilakukan pada halaman website seperti pada Gambar 10 berikut.



Gambar 10 Website Uji Klasifikasi Daun Tumbuhan Herbal

4. KESIMPULAN DAN SARAN

Hasil klasifikasi menggunakan dataset *TPHerbleaf* serta perbandingan 3 usulan arsitektur CNN yang memiliki hasil terbaik pada penelitian ini adalah arsitektur *MobileNet* dengan kombinasi *learning rate* yakni 0,0001 dan *dropout* 20%. Model pre-trained ini menghasilkan akurasi 100% untuk proses *training*, 79% untuk *validation*, dan 82% untuk *testing*. Selain dari segi akurasi yang tinggi pada dataset yang digunakan, model ini juga memiliki *size* yang kecil sehingga tidak memerlukan biaya komputasi yang besar. Terdapat beberapa pengembangan yang kedepannya dapat dilakukan 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*.

UCAPAN TERIMA KASIH

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

DAFTAR PUSTAKA

- [1] 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.
- [2] K. S. S, D. Y. Niska, I. Taufik, M. Hidayat, and D. F. Dharma, "Classification of Herbal Plants Based on Leaf Images using Convolutional Neural Network," 2022, doi: 10.4108/eai.11-10-2022.2325271.

- [3] K. P. Dewi, A. Bintoro, C. Asmarahman, and Duryat, "KEANEKARAGAMAN JENIS TUMBUHAN BERKHASIAH OBAT DI BLOK PEMANFAATAN HUTAN PENDIDIKAN KONSERVASI TERPADU TAMAN HUTAN RAYA WAR LAMPUNG," *J. PEOPLE, For. Environ.*, vol. 1, no. 2, 2021, doi: <http://dx.doi.org/10.23960/jopfe.v1i2.5115>.
- [4] 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>.
- [5] I Wayan Sukersa, *Usada Taru Pramana: Sebuah Wahana Pelestarian Flora Bahan Obat Tradisional Bali*. Denpasar: Swasta Nulus, 2017.
- [6] N. P. U. Antari, I. P. T. Suwantara, and P. E. S. K. Yudha, "Perbandingan Penggunaan Tanaman Obat dalam Usada Taru Pramana pada Penduduk Banjar Sakah Desa Pemogan dan Banjar Kerta Desa Petang," *J. Ilm. Medicam.*, vol. 4, no. 1, pp. 60–65, 2018.
- [7] 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/Sanjiwani/article/view/2059/1631>.
- [8] R. Azadnia, M. M. Al-Amidi, H. Mohammadi, M. A. Cifci, A. Daryab, and E. Cavallo, "An AI Based Approach for Medicinal Plant Identification Using Deep CNN Based on Global Average Pooling," *Agronomy*, vol. 12, no. 11, p. 2723, 2022, doi: <https://doi.org/10.3390/agronomy12112723>.
- [9] 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.
- [10] 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.
- [11] 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.
- [12] N. P. D. A. S. Dewi, M. W. A. Kesiman, I. M. G. Sunarya, I. G. A. A. D. Indradewi, and I. G. Andika, "TPHerbleaf: Dataset Untuk Klasifikasi Jenis Daun Tumbuhan Herbal Berdasarkan Lontar Usada Taru Pramana," 2023.
- [13] 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>.
- [14] 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.
- [15] 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>.
- [16] 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.
- [17] 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.
- [18] 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>.
- [19] I. Suhardin, A. Potombongi, and A. M. Islah, "MENGIDENTIFIKASI JENIS TANAMAN BERDASARKAN CITRA DAUN MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK," *J. Sist. Inf. DAN Tek. Komput.*, vol. 6, no. 2, pp. 100–108, 2021, [Online]. Available: <http://ejournal.caturasaki.ac.id/index.php/simtek/article/view/101/121>.
- [20] J. Feriawan and D. Swanjaya, "Perbandingan Arsitektur Visual Geometry Group dan MobileNet Pada Pengenalan Jenis Kayu," in *Seminar Nasional Inovasi Teknologi*, 2020, pp. 185–190, [Online]. Available: <https://proceeding.unpkediri.ac.id/index.php/inotek/article/view/84/59>.
- [21] A. S. B. Karno, D. Arif, I. S. K. Wardhana, and E. S. Moreta, "Diagnosa COVID-19 Chest X-Ray Menggunakan Arsitektur Inception Resnet," *J. Inf. Inf. Secur.*, vol. 2, no. 1, pp. 57–66, 2021, [Online]. Available: <https://ejurnal.ubharajaya.ac.id/index.php/jiforty/article/view/646/523>.
- [22] K. Sreenath P *et al.*, "Deep Learning Classification of Lake Zooplankton," *Front. Microbiol.*, vol. 12, 2021, doi: 10.3389/fmicb.2021.746297.
- [23] 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.
- [24] D. E. Birba, "A Comparative study of data splitting algorithms for machine learning model selection," KTH Royal Institute Of Technology, 2020.
- [25] I. W. A. Purnawibawa, I. N. Purnama, and I. N. Y. A. Wijaya, "Komparasi Algoritme K-Nearest Neighbors Dan Support Vector Machines Dalam Prediksi Layanan Produk ICONNET," *Progresif J. Ilm. Komput.*, vol. 18, no. 2, pp. 271–282, 2022, doi: 10.35889/progresif.v18i2.894.
- [26] K. Alomar, H. I. Aysel, and X. Cai, "Data Augmentation in Classification and Segmentation: A Survey and New Strategies," *J. Imaging*, vol. 9, no. 2, p. 46, 2023, doi: 10.3390/jimaging9020046.
- [27] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," *arXiv:1905.11946*, 2019, doi: 10.48550/arXiv.1905.11946.
- [28] I. Syurfi, "PENERAPAN DEEP LEARNING DENGAN CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI CITRA DIABETIC DENGAN ARSITEKTUR EFFICIENTNET-B7," UNIVERSITAS ISLAM NEGERI SULTAN SYARIF KASIM, 2021.
- [29] J. Bjorck, C. Gomes, B. Selman, and K. Q. Weinberger, "Understanding Batch Normalization," 2018, doi: 10.48550/arXiv.1806.02375.