

Deep Learning untuk Identifikasi Daun Tanaman Obat Menggunakan Transfer Learning MobileNetV2

Rio Juan Hendri Butar-Butar¹, Noveri Lysbetti Marpaung^{2,*}

^{1,2}Program Studi Teknik Informatika, Fakultas Teknik, Universitas Riau, Pekanbaru

^{1,2}Kampus Bina Widya Km 12,5, Kota Pekanbaru, 28293, Indonesia

email: ¹rio.juan6542@student.unri.ac.id, ²noveri.marpaung@eng.unri.ac.id

Abstract – Medicinal plants are plants used as alternative medicines for healing or preventing various diseases due to their active substances. The utilization of medicinal plants in Indonesia has been widespread among the community since ancient times and is a heritage passed down from ancestors. Medicinal plants have leaf structures that are almost similar between one plant and another, which can lead to confusion for some people and require precision in identifying the leaves of medicinal plants. Incorrect identification can have negative consequences for the users. In recent years, deep learning has been used to identify objects because of its ability to interpret images. This study used a transfer learning method to identify medicinal plants. Transfer learning utilizes a pre-trained model to learn and perform new tasks, making it suitable for smaller datasets. The pre-trained model used in this study is MobileNetV2. MobileNetV2 has a lightweight architecture and high accuracy. Fine-tuning techniques were applied in this study to improve the model's performance. Several experiments were conducted with parameters such as epochs and fine-tuning layers to obtain the best results. The research yielded a training accuracy of 97%, validation accuracy of 96%, and testing accuracy of 93%.

Abstrak – Tanaman obat adalah jenis tanaman yang digunakan sebagai alternatif obat penyembuhan ataupun upaya pencegahan berbagai penyakit dikarenakan zat aktif yang dimiliki oleh tanaman tersebut. Pemanfaatan tanaman obat di Indonesia sudah sangat umum digunakan oleh masyarakat sejak zaman dahulu dan merupakan warisan dari nenek moyang terlebih dahulu. Tanaman obat memiliki bentuk daun yang hampir serupa antara satu tanaman dengan tanaman lainnya. Hal ini membuat beberapa masyarakat memiliki kekeliruan dan membutuhkan ketelitian dalam mengidentifikasi daun tanaman obat. Dikarenakan kesalahan dalam identifikasi dapat menimbulkan hal buruk bagi para penggunanya. Dalam beberapa tahun terakhir, untuk mengidentifikasi sebuah objek dapat menggunakan *deep learning* karena kemampuannya dalam menginterpretasikan gambar. Dalam penelitian ini digunakan metode *transfer learning* untuk mengidentifikasi tanaman obat. Dimana *transfer learning* menggunakan model yang terlebih dahulu di *training* dan dijadikan dasar pembelajaran untuk melakukan pekerjaan yang baru sehingga dapat digunakan untuk data yang lebih sedikit. *Pretrained model* yang digunakan pada penelitian ini adalah MobileNetV2. MobileNetV2 memiliki arsitektur yang ringan dan memiliki akurasi yang tinggi. Pada penelitian ini diterapkan teknik *fine tune* untuk meningkatkan performa model. Beberapa percobaan dilakukan dengan parameter yang berbeda seperti *epoch* dan *layer fine tune* untuk mendapatkan hasil terbaik.

Hasil penelitian ini mendapatkan akurasi 97% *training*, 96% validasi dan 93% pengujian.

Kata Kunci – Tanaman Obat, Transfer Learning, Fine Tune, Deep Learning, MobileNetV2.

I. PENDAHULUAN

Negara kepulauan yang terbentang di sepanjang garis khatulistiwa membuat Indonesia menjadi negara *megabiodiversity* dengan ribuan bahkan jutaan tanaman, hewan dan mikroorganisme lainnya [1]. Setidaknya lebih dari 30.000 jenis tanaman tumbuh subur di daratan Indonesia dengan 6.000-7.000 jenis diantaranya tergolong sebagai tanaman obat [2]. Keberadaan tanaman obat sudah ada sejak jaman dahulu kala dan merupakan warisan turun temurun. Tanaman obat sudah terbukti dapat mengobati berbagai macam penyakit, salah satu tanaman obat yang paling terkenal di Indonesia adalah daun sirih. Daun sirih mampu untuk menyembuhkan beberapa penyakit seperti menghindari bau badan, sebagai obat sesak nafas, mengatasi masalah tenggorokan dan paru-paru [3].

Tanaman pada umumnya memiliki bentuk daun yang serupa sama hal nya dengan tanaman obat. Kemiripan morfologi daun antara sesama tanaman obat maupun dengan tanaman lainnya membutuhkan ketelitian dalam mengidentifikasi tanaman tersebut

Kesalahan dalam mengidentifikasi tanaman obat dapat menimbulkan hal buruk yang akan terjadi pada para penggunanya seperti alergi bahkan keracunan, dikarenakan ketidaksesuaian antara penyakit yang diderita dengan obat yang digunakan. Dalam beberapa tahun terakhir, *deep learning* banyak digunakan untuk mengidentifikasi objek gambar dikarenakan kemampuannya dalam menginterpretasikan data dengan meniru mekanisme kerja otak manusia [4]. Untuk menerapkan *deep learning* dapat digunakan metode *transfer learning*. Dimana *transfer learning* adalah pengembangan dari *deep learning* yang menggunakan model yang sudah dilatih sebelumnya (*pre-trained model*) untuk mengerjakan tugas yang baru [5].

Transfer learning memungkinkan mesin untuk mempelajari data dengan jumlah yang sedikit [6]. Salah satu *pretrained model* yang memiliki performa yang baik adalah MobileNetV2. MobileNetV2 merupakan model yang dikembangkan oleh Google yang memiliki arsitektur yang ringan. Hal ini memungkinkan MobileNetV2 untuk dapat berjalan pada perangkat dengan performa yang tidak terlalu

*) penulis korespondensi: Noveri Lysbetti Marpaung
Email: noveri.marpaung@eng.unri.ac.id

tinggi [7]. Selain arsitektur yang ringan, MobileNetV2 juga dapat mengidentifikasi objek gambar dengan akurasi yang tinggi [8]. Maka dari itu, *transfer learning* dengan MobileNetV2 merupakan metode yang tepat digunakan untuk mengidentifikasi daun tanaman obat.

Berdasarkan uraian diatas, maka penelitian ini mengimplementasikan *deep learning* menggunakan metode *transfer learning* untuk mengidentifikasi daun tanaman obat. Ada empat jenis tanaman obat yang digunakan pada penelitian ini diantaranya Daun Binahong, Daun Sirih, Daun Salam, Daun Penyambung Nyawa. Tanaman obat ini dipilih dikarenakan morfologi daun tanaman ini hampir mirip. Selain itu, tanaman ini juga tumbuh disekitar masyarakat dan sangat mudah untuk didapatkan. MobileNetV2 dipilih sebagai *pre-trained* model untuk mengimplementasikan metode *transfer learning*. Penelitian ini akan menghasilkan model yang mempelajari input yang diberikan menggunakan metode *transfer learning* dan dapat digunakan untuk mengidentifikasi daun tanaman obat dengan tepat dan dapat digunakan bagi masyarakat yang mengkonsumsi tanaman obat sehingga mengurangi resiko kesalahan dalam mengidentifikasi daun tanaman obat.

II. PENELITIAN YANG TERKAIT

Terdapat beberapa penelitian sebelumnya yaitu Penelitian oleh Vimal K. Shrivastava dkk mengklasifikasikan penyakit pada tanaman padi menggunakan metode *transfer learning*. Model yang digunakan sebagai *pre-trained* model pada penelitian ini adalah Alexnet. Hasil akurasi yang didapatkan adalah 91.37 % untuk pembagian dataset *training* dan *testing* dengan persentase 80%:20% [9].

Penelitian oleh Imam Fauzi Annur mengklasifikasikan tingkat keparahan penyakit leafblast tanaman padi menggunakan *transfer learning* MobileNetV2. Rata-rata valuasi akurasi yang didapatkan pada penelitian ini yaitu 78.33%. Peneliti berharap agar penelitian selanjutnya dapat menggunakan dataset yang lebih banyak [10].

Penelitian oleh Marcia Hon dkk pada tahun 2017 mengklasifikasikan Alzheimer menggunakan OASIS dataset. Penelitian ini menggunakan metode *transfer learning* dengan membandingkan 2 model yaitu VGG-16 dan InceptionV4. Akurasi terbaik dihasilkan oleh model InceptionV4 dengan 96.25 % dan untuk VGG-16 92.3 % [11].

Penelitian oleh Rupa Patel dkk pada tahun 2020 untuk mengklasifikasikan diabetes retinopati menggunakan metode *transfer learning* MobileNetV2. Pada penelitian ini dihasilkan model dengan akurasi 70% sebelum dilakukan *fine tune*. Setelah dilakukan *fine tune* model menghasilkan 91 % akurasi [5].

Penelitian oleh Arif Tirtana dkk pada tahun 2021 mengidentifikasi citra tanaman obat menggunakan metode *transfer learning* dengan Xception. Dataset yang digunakan berupa 20 jenis tanaman obat dengan masing-masing tanaman obat memiliki 50 gambar. Akurasi tertinggi yang didapatkan pada penelitian ini adalah 96.3 % [12].

Penelitian oleh Thiru Siddharth dkk pada tahun 2022 mengklasifikasikan spesies tanaman menggunakan *transfer learning* VGG-19. Penelitian ini mengklasifikasikan 15 spesies tanaman dengan masing-masing tanaman memiliki 75 gambar. Dataset dibagi menjadi data *train* dan data *testing*

dengan persentase 70%:30%. Akurasi yang didapatkan pada penelitian ini adalah 99.70 % [13].

Penelitian oleh Y. R. Azeez tahun 2019 mengidentifikasi tanaman obat sri lanka menggunakan metode *transfer learning* dengan InceptionV3. Penelitian ini mengklasifikasikan 5 jenis tanaman obat. Akurasi yang didapatkan pada penelitian ini adalah 88.6 % [14].

Penelitian yang dilakukan oleh Tatsuihiro Akiyama dkk pada tahun 2019 yang mengidentifikasi daun tanaman obat yang ada di Hokkaido menggunakan *transfer learning*. Penelitian ini membandingkan tiga model yaitu VGG19, MobileNet, dan MobileNetV2 untuk mengidentifikasi daun tanaman obat. Dari ketiga model yang dibandingkan, MobileNetV2 mendapatkan hasil terbaik dengan waktu kalkulasi paling cepat. Dengan menggunakan MobileNetV2 didapatkan nilai presisi 0.993, 0.992 untuk nilai recall dan F1-Score [15].


Penelitian oleh Vina Ayumi dkk tahun 2022 menggunakan metode *transfer learning* dan membandingkan beberapa pretrained model seperti VGG16, VGG19, dan MobileNetV2 dalam mengidentifikasi daun tanaman obat. Data yang diperoleh pada penelitian ini sebanyak 1500 data gambar dari 30 jenis daun tanaman obat. Model dibandingkan berdasarkan teknik *fine tuning* dan MobileNetV2 setelah dilakukan *fine tuning* menghasilkan hasil yang baik pada saat pelatihan dan pengujian. MobileNetV2 mencapai akurasi 81.82 % pada saat pengujian dan 98.41 % pada saat pelatihan. MobileNetV2 memiliki waktu komputasi paling cepat dibandingkan dengan model lainnya pada saat pelatihan identifikasi daun tanaman obat.

Penelitian yang dilakukan oleh Denise Pechebovicz dkk pada tahun 2020. Penelitian ini menggunakan metode *transfer learning* menggunakan MobileNetV2 sebagai acuan pembelajaran. Penelitian ini mengidentifikasi tanaman beracun dan tanaman obat berdasarkan morfologi daun tanaman tersebut. Penelitian ini juga mengimplementasikan data augmentasi sebagai proses *preprocessing* data. Dataset yang digunakan pada penelitian ini sebanyak 10.162 dibagi dengan persentase 80 % data latih dan 20 % data uji. Penelitian ini juga menerapkan teknik *fine tuning* untuk meningkatkan akurasi. Akurasi akhir yang didapatkan pada penelitian ini adalah 94 %

III. METODE PENELITIAN

A. Tahapan Penelitian

Pada penelitian ini digunakan metode penelitian *research and development* dimanatahapan pada penelitian ini, secara umum terbagi atas tiga langkah utama yaitu studi pendahuluan, desain dan pengembangan serta pengujian. Penelitian dimulai dengan observasi kemudian dilanjutkan dengan studi literatur tanaman obat yang akan diidentifikasi dan metode *transfer learning* yang akan digunakan. Kemudian di dapatkan identifikasi masalah dari penelitian ini dimana kemiripan daun tanaman obat menimbulkan kesalahan dalam mengidentifikasi daun tanaman obat. Mengumpulkan data dua tanaman obat yang kemudian di *preprocessing*. Setelah data diolah, maka dilakukan pemodelan dan model yang dihasilkan akan dilatih kemudian akan diuji jika tidak memenuhi akurasi lebih dari 80 % maka model akan dilatih kembali seperti yang digambarkan pada Gbr.1.



Gbr. 1 Tahapan penelitian.

B. Dataset

Data yang digunakan pada penelitian ini berupa data gambar empat jenis daun tanaman obat yaitu Daun Binahong, Daun Sirih, Daun Salam, Daun Penyambung Nyawa. Pengumpulan data dilakukan dengan dua cara yaitu pengambilan data secara langsung dan mengambil data dari internet. Pengumpulan data secara langsung dilakukan dengan mengambil foto tanaman obat secara langsung. Selain pengumpulan data secara langsung, pengumpulan data juga dilakukan dengan mengumpulkan data gambar dari berbagai sumber di internet. Data yang didapatkan sebanyak 600 data gambar. Data yang didapatkan kemudian dibagi menjadi dua yaitu data latih dan data uji. Persentase pembagian 80 % data latih dan 20 % data uji. Detail dataset yang digunakan pada penelitian ini ditunjukkan seperti pada Tabel I.

TABEL I
DETAIL DATASET


Nama Kelas	Jumlah	Data Latih	Data Uji
Daun Binahong	150	120	30
Daun Penyambung Nyawa	150	120	30
Daun Salam	150	120	30
Daun Sirih	150	120	30

C. Preprocessing Data

Setelah mengumpulkan data, langkah selanjutnya adalah melakukan preprocessing data. *Preprocessing* dilakukan untuk meningkatkan kualitas data yang digunakan dalam penelitian [16]. Dalam penelitian ini, *Preprocessing* data yang akan dilakukan adalah augmentasi data dan *resizing* data. Augmentasi data dilakukan untuk memperluas variasi data yang digunakan [17]. Karena keterbatasan jumlah data yang tersedia, langkah ini sangat penting. Augmentasi data hanya dilakukan pada data pelatihan untuk mengurangi kemungkinan *overfitting* saat proses pelatihan (Naufal & Kusuma, 2021).

Augmentasi yang dilakukan termasuk *flip*, rotasi, dan *zoom*. *Flip* digunakan untuk membalik gambar secara horizontal atau vertikal. Rotasi digunakan untuk memutar gambar sesuai dengan sudut yang ditentukan. Sementara itu, *zoom* digunakan untuk memperbesar data gambar. *Resizing* data digunakan untuk menyamaratakan semua dimensi gambar sesuai dengan kebutuhan *input layer*. Pada saat pengumpulan data, data yang dikumpulkan memiliki dimensi

yang berbeda-beda. Maka dari itu, pada penelitian ini data kan di *resize* menjadi 224 x 224 *pixel*. Hasil *preprocessing* data ditunjukkan pada Gbr.2.

Gbr. 2 Hasil *preprocessing* data.

D. Transfer Learning


Metode *transfer learning* membutuhkan penggunaan model yang telah dilatih sebelumnya, yang dikenal sebagai *pretrained model*, untuk mempelajari tugas yang baru [18]. Pada penelitian ini, *pretrained model* yang digunakan adalah MobileNetV2. Dalam metode *transfer learning*, *pretrained model* tersebut digunakan untuk ekstraksi fitur. Semakin banyak *pretrained model* dilatih dengan data sebelumnya, semakin baik kemampuannya dalam mengenali objek baru dengan data yang lebih sedikit [19]. Pelatihan dengan menggunakan metode *transfer learning* dapat dilakukan dengan mudah dan cepat karena menggunakan dataset yang terbatas [20].

Pada penelitian ini, model dasar yang dijadikan acuan pembelajaran adalah MobileNetV2. Dimana model ini memiliki parameter yang lebih sedikit sehingga sangat optimat pada saat proses pembelajaran. Arsitektur MobileNetV2 menerapkan *Depthwise Separable Convolution* sebagai lapisan utamanya. *Depthwise Separable Convolution* digunakan untuk membangun sebuah neural network yang memiliki bobot lebih ringan. *Depthwise Separable Convolution* akan membagi konvolusi menjadi dua yaitu *Depthwise Convolution* dan *Pointwise Convolution*. *Depthwise Convolution* mengaplikasikan satu filter untuk setiap *input channel* pada model yang kemudian hasilnya akan dilakukan konvolusi 1x1 pada *Pointwise Convolution* [21].

MobileNetV2 pada penelitian ini, dijadikan sebagai *feature extraction* dimana *fully connected layer* atau *layer* terakhir pada MobileNetV2 akan dihapus dan digantikan dengan *layer classifier* untuk tanaman obat. MobileNetV2 memiliki 154 *layer* untuk ekstraksi fitur. *Layer* pertama yang ditambahkan adalah *flatten layer*. Hasil fitur yang dihasilkan dari proses ekstraksi fitur dengan MobileNetV2 akan diubah menjadi vektor satu dimensi melalui proses *flatten* [22]. Selanjutnya, dilakukan penambahan *fully connected layer*

yang digunakan untuk mengubah fitur multidimensi menjadi vektor satu dimensi [23]. Fungsi aktivasi juga digunakan untuk menentukan *output* dari sebuah *node* [24], [25]. Salah satu fungsi aktivasi yang digunakan adalah *Rectified Linear Unit* (ReLU), yang menghasilkan nilai 0 untuk *input* negatif dan menghasilkan nilai input itu sendiri untuk *input* positif [24]. *Layer* selanjutnya yang ditambahkan adalah *dropout layer*.

Dropout menghilangkan beberapa *neuron* dari jaringan selama proses pelatihan secara acak, sehingga membantu menghindari *overfitting* dan meningkatkan generalisasi model [26]. *Dropout layer* yang digunakan memiliki *dropout rate* sebesar 0.2. Langkah selanjutnya adalah menginisialisasi *layer output*, dengan jumlah unit sebanyak empat sesuai dengan jumlah kelas tanaman obat yang akan diklasifikasikan, sehingga *dense layer* yang digunakan memiliki empat nilai. Fungsi aktivasi yang digunakan adalah *softmax*. *Softmax* digunakan untuk menghitung probabilitas untuk setiap label. Kelas dengan probabilitas tertinggi akan menjadi hasil identifikasi. Gbr.3 menunjukkan arsitektur model yang digunakan.



Gbr. 3 Arsitektur Model.

E. Simulasi Pelatihan

Setelah selesai merancang arsitektur model selama proses pemodelan, langkah selanjutnya adalah mengkonfigurasi model agar dapat melakukan pelatihan sesuai dengan parameter yang ditentukan. Pada proses ini, terdapat beberapa parameter yang digunakan, antara lain *optimizer*, *loss*, *batch_size*. Parameter *optimizer* digunakan untuk memilih algoritma *optimizer* yang akan digunakan selama proses pelatihan, dan dalam penelitian ini, *optimizer* yang digunakan adalah Adam. Algoritma Adam diperkenalkan oleh Diederik P. Kingma pada tahun 2015. Adam merupakan algoritma optimasi yang menggabungkan kelebihan dari algoritma Adagrad dan RMSProp. Adam mudah diimplementasikan, efisien secara komputasi, dan membutuhkan sedikit penggunaan memori [27]. Parameter *loss* untuk menentukan fungsi *loss* yang akan digunakan, dan dalam penelitian ini digunakan fungsi *Sparse Categorical Cross Entropy*. *Batch_size* yang digunakan pada penelitian ini adalah 32.

Untuk menghasilkan model pelatihan terbaik dengan *transfer learning*, ada beberapa skenario pelatihan yang akan dilakukan. Model terlebih dahulu dilatih dengan *epoch* mulai dari 15, 20 dan 25. Setelah itu, model yang dihasilkan akan dilakukan *fine tune* dari *layer* yang berbeda. Skenario pertama, model yang sebelumnya sudah dilatih akan di *fine tune* pada *layer* ke-87 dan dilatih kembali dengan *epoch fine tune*. Skenario kedua akan di *fine tune* ada *layer* ke-100 dengan *epoch* 30. Pada penelitian ini, *learning rate* yang digunakan selama pelatihan adalah 0.0001, dan *learning rate* yang

digunakan saat pelatihan *fine tuning* adalah 0.00001. Ada beberapa percobaan yang akan dilakukan untuk mendapatkan hasil terbaik. Tabel II memaparkan skenario percobaan pelatihan yang dilakukan.

TABEL II
SKENARIO PERCOBAAN PELATIHAN

Parameter	Skenario 1			Skenario 2		
Epoch	15	20	25	15	20	25
Optimizer	Adam	Adam	Adam	Adam	Adam	Adam
Batch_size	32	32	32	32	32	32
Learning rate	0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
Fine tune (layer ke-)	87	87	87	100	100	100
Epoch fine tune	30	30	40	30	30	40
Learning rate fine tune	0.00001	0.00001	0.00001	0.00001	0.00001	0.00001

IV. HASIL DAN PEMBAHASAN

Terdapat dua skenario pada penelitian ini, dimana model akan dilatih dengan parameter yang berbeda akan tetapi tetap dengan arsitektur yang sama. Hal ini dilakukan untuk mendapatkan hasil terbaik terutama dalam hal akurasi. Pada skenario pertama, model terlebih dahulu dilatih dengan *epoch* yang berbeda yaitu 15, 20, dan 25. Yang kemudian setelah dilatih akan dilakukan *fine tune* pada *layer* ke-87 dengan parameter *learning rate* yang lebih rendah yaitu 0.00001. Hasil yang diperoleh ditampilkan seperti pada Tabel III.

TABEL III
HASIL PELATIHAN SKENARIO 1


Percobaan	Model	Fine tune	Epoch	Akurasi	
				Train	Val
1	Model		15	0.9896	0.9476
	Fine Tune	87	30	0.9870	0.9375
2	Model		20	0.9922	0.9375
	Fine Tune	87	30	0.9766	0.9688
3	Model		25	0.9818	0.9167
	Fine Tune	87	40	0.9974	0.9583

. Setelah dilakukan pelatihan pada skenario pertama, hasil terbaik didapatkan pada percobaan 2 dimana model dilatih dengan *epoch* 20 kemudian dilakukan *fine tune* pada *layer* ke-87 dan dilatih kembali dengan *epoch* 30 dengan total *epoch* pelatihan adalah 50. Grafik hasil pelatihan pada percobaan 2

sebelum dilakukan *fine tune* ditunjukkan pada Gbr. 4 dan setelah dilakukan *fine tune* ditunjukkan pada Gbr 5.



Gbr. 4 Grafik hasil percobaan 2 skenario 1 sebelum *fine tune*.




Gbr. 5 Grafik hasil percobaan 2 skenario 1 setelah *fine tune*.

Nilai akurasi yang didapatkan adalah 0.9922 pada *training* dan 0.9375 pada *validasi*. Terdapat jarak yang cukup jauh antara akurasi yang dihasilkan oleh *training* dan *validasi*. Hal ini menunjukkan adanya kemungkinan model mengalami *overfitting*. Untuk nilai *loss* juga pada *training* untuk setiap *epoch* sedangkan pada *validasi* nilai *loss* naik turun dan tidak stabil. Kemudian dilakukan *fine tune* dan nilai akurasi yang didapatkan adalah 0.9766 pada *training* dan 0.9688 pada *validasi*. Selisih akurasi yang didapatkan sangat baik yaitu 0.078. Model yang dilatih mendapatkan akurasi yang cukup baik daripada percobaan lainnya pada skenario satu. *Epoch* yang digunakan sesuai dengan *layer fine tune* yang ditetapkan sehingga menghasilkan hasil yang baik. Sama halnya dengan skenario pertama, yang menjadikan perbedaan antara kedua skenario ini adalah *layer fine tune* yang digunakan. Hasil pelatihan untuk skenario 2 dipaparkan pada Tabel IV.


TABEL IV
HASIL PELATIHAN SKENARIO 2

Percobaan	Model	Fine tune	Epoch	Akurasi	
				Train	Val
1	Model		15	0.9948	0.9583
	Fine Tune	100	30	0.9948	0.9375
2	Model		20	0.9818	0.9062
	Fine Tune	100	30	0.9792	0.9375
3	Model		25	0.9844	0.9375
	Fine Tune	100	40	0.9948	0.9583

Setelah dilakukan pelatihan pada skenario kedua, hasil terbaik didapatkan pada percobaan 3 dimana model dilatih dengan *epoch* 25 kemudian dilakukan *fine tune* pada *layer* ke-100 dan dilatih kembali dengan *epoch* 40 dengan total *epoch* pelatihan adalah 65. Grafik hasil pelatihan pada percobaan 3 skenario 2 sebelum *fine tune* ditunjukkan pada Gbr 6 dan setelah *fine tune* ditunjukkan pada Gbr.7.



Gbr. 6 Grafik hasil percobaan 3 skenario 2 sebelum *fine tune*.



Gbr. 7 Grafik hasil percobaan 3 skenario 2 setelah *fine tune*.

Sebelum dilakukan *fine tune* akurasi yang didapatkan 0.9844 pada *training* dan 0.9375 pada *validasi*. Akurasi yang dihasilkan tidak terlalu menunjukkan kenaikan

signifikan. Nilai *loss* yang dihasilkan cenderung naik turun dan tidak stabil. Setelah dilakukan *fine tune* hasil akurasi yang di dapatkan 0.9948 pada *training* dan 0.9583 pada validasi. Setelah di *fine tune*, akurasi yang didapatkan mengalami peningkatan yang cukup baik. Jarak antara kedua akurasi tersebut juga cukup baik yaitu 0.0365 sehingga hasil akurasi yang dihasilkan cukup efektif.

Setelah melakukan pelatihan dengan total 6 percobaan dengan dari 2 skenario berbeda yang menggunakan parameter berbeda, percobaan ke-2 dari skenario-1 menghasilkan akurasi yang baik dan tidak terlalu jauh selisih akurasi antara data pelatihan dan data validasi, sehingga risiko terjadinya *overfitting* dapat diminimalisir. Percobaan ke-3 pada skenario 2 juga menghasilkan hasil yang baik akan tetapi selisih akurasi yang didapatkan cukup jauh jika dibandingkan dengan percobaan 2 pada skenario-1. Kedua percobaan ini memiliki jumlah *epoch* yang berbeda. *Epoch* yang terlalu sedikit menghasilkan akurasi yang tidak seimbang antara data pelatihan dan data validasi, pada kedua skenario yang dapat menyebabkan *overfitting* pada model. *Epoch* yang terlalu besar juga tidak selalu menghasilkan hasil akurasi yang baik. Maka dari itu, jumlah *epoch* juga harus disesuaikan dengan parameter lainnya sehingga menghasilkan hasil yang baik.

Hasil pelatihan dari kedua skenario membuktikan bahwa teknik *fine tune* dapat meningkatkan performa model. Akan tetapi, menerapkan *fine tune* memakan waktu yang lebih lama daripada pelatihan tanpa *fine tune*. Setelah melakukan 6 percobaan dari dua skenario yang berbeda *fine tune* dari layer ke-87, menghasilkan hasil yang lebih baik daripada *fine tune* dari layer ke-100. Hal ini disebabkan karena saat melakukan *fine tune* dari layer ke-87, layer di bawahnya akan dilatih kembali sehingga model masih mempertahankan pengetahuan dari data sebelumnya dan ditambah dengan pengetahuan dari data baru. Sedangkan *fine tune* dari layer ke-100, layer yang dilatih kembali lebih sedikit sehingga tidak menghasilkan peningkatan yang signifikan pada model. Dan *fine tune* layer ke-87 memakan waktu yang lebih lama daripada *fine tune* layer ke-100. Dalam penelitian ini, semua percobaan menghasilkan model dengan akurasi lebih dari 80% selama pelatihan, tetapi percobaan ke-2 pada skenario -1 menghasilkan akurasi model terbaik dibandingkan dengan percobaan lainnya.

MobileNetV2 memiliki efisiensi yang tinggi dikarenakan arsitektur MobileNetV2 yang menggunakan *depthwise separable convolution* sehingga dapat mengurangi kompleksitas komputasi secara signifikan. Dengan MobileNetV2 membuat proses pelatihan dapat dilakukan relatif lebih cepat. MobileNetV2 juga memiliki kemampuan generalisasi yang baik, hal ini dikarenakan sebelumnya MobileNetV2 sudah dilatih dengan dataset ImageNet sehingga sudah mempelajari fitur-fitur umum pada objek gambar. Sehingga untuk mengidentifikasi objek yang baru yaitu daun tanaman obat, MobileNetV2 dapat mengidentifikasi objek tersebut dengan mudah. Dengan kurangnya data yang dimiliki, transfer learning sangat baik digunakan.

Transfer learning dengan MobileNetV2 memungkinkan untuk menghemat waktu serta sumber daya yang diperlukan. Hal ini dikarenakan transfer learning memungkinkan kita untuk menggunakan fitur-fitur yang telah

dipelajari oleh MobileNetV2, yang mencakup pola tekstur, bentuk, dan karakteristik visual yang berguna dalam pengenalan objek gambar. Dengan menggunakan transfer learning pada penelitian ini menghasilkan model yang memiliki ekstraksi fitur serta generalisasi objek gambar yang lebih baik. Dibuktikan dengan hasil pelatihan yang sudah dilakukan menghasilkan akurasi yang sangat baik walaupun menggunakan dataset yang cenderung lebih sedikit. Sebelum dilakukan *fine tune* akurasi yang didapatkan juga sudah baik dan ketika dilakukan teknik *fine tune*, teknik ini mendukung metode transfer learning untuk menghasilkan model yang lebih baik.

Setelah dilakukan proses pelatihan dan didapatkan model terbaik yaitu model pada percobaan dua skenario pertama, model yang didapatkan kemudian diuji menggunakan data uji. Data uji pada penelitian ini digunakan sebanyak 120 data, dimana 30 data untuk setiap kelas. Pengujian dilakukan dengan meng-*upload* gambar kemudian model di load dan digunakan fungsi *predict* pada tensorflow untuk memprediksi gambar tersebut sesuai dengan model yang sudah dilatih sebelumnya. Setelah semua data di uji maka hasil tersebut dapat disajikan menggunakan *confusion matrix* seperti yang ditunjukkan pada Gbr 8.

ACTUAL	Daun Binahong	Daun Penyambung Nyawa	Daun Salam	Daun Sirih
	25	1	2	2
	0	30	0	0
	0	3	27	0
PREDICTED	Daun Binahong	Daun Penyambung Nyawa	Daun Salam	Daun Sirih
	25	1	2	2
	0	30	0	0
	0	3	27	0

Gbr. 8 Confusion matrix.

Daun Binahong berhasil diprediksi dengan benar sebanyak 25 data, Daun Penyambung Nyawa berhasil diprediksi dengan benar sebanyak 30 data, Daun Salam berhasil diprediksi dengan benar sebanyak 27 data dan Daun sirih sepenuhnya berhasil diprediksi dengan benar oleh model. Persentase model dalam memprediksi masing-masing daun tanaman obat adalah 83 % untuk daun binahong, 100% untuk daun penyambung nyawa, 93% untuk daun salam dan 100% untuk daun sirih. Sehingga didapatkan persentase keberhasilan model dalam memprediksi seluruh data uji adalah 94,16 %. Daun sirih memiliki akurasi yang sempurna dikarenakan kualitas gambar yang didapatkan. Dapat disimpulkan bahwa model pelatihan yang digunakan dapat memprediksi data uji dengan baik dan dapat melebihi target penelitian. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan teknologi identifikasi tanaman obat dengan lebih cepat dan akurat serta dapat memberikan pengetahuan tentang metode transfer learning menggunakan MobileNetV2.

V. KESIMPULAN

Berdasarkan hasil pelatihan dan pengujian yang sudah dilakukan pada penelitian ini maka dapat ditarik kesimpulan Berdasarkan hasil pelatihan dan pengujian yang dilakukan dalam penelitian ini, dapat ditarik kesimpulan yaitu hasil akurasi terbaik diperoleh pada percobaan ke-2 skenario-1 dengan fine tune layer ke-87 dan total epoch 50, dengan akurasi 97.66 % pada tahap pelatihan dan 96.88 % pada tahap validasi. Selain itu, perbedaan antara kedua akurasi tersebut juga lebih kecil dibandingkan dengan percobaan lainnya, yaitu hanya sebesar 0.0078. Setelah dilakukan pengujian dengan data uji didapatkan akurasi 94.16 %.

Dalam penelitian ini, parameter epoch memiliki pengaruh signifikan terhadap hasil pelatihan dimana epoch harus disesuaikan dengan layer fine tune. Fine-tuning terbaik ditemukan pada layer ke-87. Pada penelitian ini metode transfer learning dengan MobileNetV2 yang digunakan berhasil dengan sangat baik dalam mengidentifikasi daun tanaman obat. Dibantu dengan teknik fine tune yang dilakukan dapat meningkatkan performa model seperti yang sudah diterapkan pada penelitian terdahulu. Penelitian ini membuktikan transfer learning memiliki kemampuan generalisasi yang baik ditambah dengan kemampuan MobileNetV2 membuat metode ini sangat efisien untuk digunakan. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan teknologi identifikasi daun tanaman obat menggunakan deep learning dan transfer learning.

Namun, kekurangan dari penelitian ini adalah perlu adanya upaya lebih lanjut untuk meningkatkan akurasi prediksi dengan menambah dan memperluas variasi data yang digunakan. Saran untuk penelitian selanjutnya adalah menambahkan variasi data guna menghasilkan hasil yang lebih baik. Selain itu, diharapkan peneliti selanjutnya dapat menggunakan pretrained model lainnya seperti InceptionV4, Resnet serta Alexnet agar mendapatkan metode terbaik untuk identifikasi daun tanaman obat.

DAFTAR PUSTAKA

- [1] I. Aripin, T. Hidayat, and N. Rustaman, "Pengembangan Program Perkuliahan Biologi Konservasi Berbasis Citizen Science Project," *Pedagog. Hayati*, vol. 5, no. 1, pp. 1–9, 2021.
- [2] Isman, Andani Ahmad, and Abdul Latief, "Perbandingan Metode KNN Dan LBPH Pada Klasifikasi Daun Herbal," *J. RESTI (Rekayasa Sist. dan Teknol. Informatika)*, vol. 5, no. 3, pp. 557–564, 2021, doi: 10.29207/resti.v5i3.3006.
- [3] A. Naufalza, "Manfaat Daun Sirih pada Pencegahan penyakit Jantung Koroner," *J. Hoslistic Tradis. Med.*, vol. 02, no. 02, pp. 595–599, 2021.
- [4] Y. Xin et al., "Machine Learning and Deep Learning Methods for Cybersecurity," *IEEE Access*, vol. 6, no. c, pp. 35365–35381, 2018, doi: 10.1109/ACCESS.2018.2836950.
- [5] R. Patel and A. Chaware, "Transfer learning with fine-tuned MobileNetV2 for diabetic retinopathy," *2020 Int. Conf. Emerg. Technol. INCET*, pp. 6–9, 2020, doi: 10.1109/INCET49848.2020.9154014.
- [6] Y. Gulzar, "Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique," *Sustain.*, vol. 15, no. 3, 2023, doi: 10.3390/su15031906.
- [7] W. Hastomo, "Convolution Neural Network Arsitektur Mobilenet-V2 Untuk Mendeteksi Tumor Otak," *Pros. SeNTIK*, vol. 5, no. 1, pp. 17–21, 2021.
- [8] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 4510–4520, 2018, doi: 10.1109/CVPR.2018.00474.
- [9] V. K. Shrivastava, M. K. Pradhan, S. Minz, and M. P. Thakur, "Rice plant disease classification using transfer learning of deep convolution neural network," *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. 3, no. 6, pp. 631–635, 2019.
- [10] I. F. Annur, J. Umami, M. N. Annafii, T. Oddy, and V. Putra, "Klasifikasi Tingkat Keparahan Penyakit Leafblast Tanaman Padi Menggunakan Abstrak," *Fountain Informatics J.*, vol. 8, no. 1, 2023.
- [11] M. Hon and N. M. Khan, "Towards Alzheimer's disease classification through transfer learning," *Proc. - 2017 IEEE Int. Conf. Bioinforma. Biomed. BIBM 2017*, vol. 2017-Janua, pp. 1166–1169, 2017, doi: 10.1109/BIBM.2017.8217822.
- [12] A. Tirtana, M. G. T. Febriani, D. I. Masrui, and A. A. Aisyah, "Herbify: Aplikasi Perangkat Bergerak Berbasis Komputasi Awan Untuk Mengidentifikasi Tanaman Herbal Indonesia Menggunakan Cnn Model Xception," *J. Ilm. Educ. Pendidik. dan Inform.*, vol. 8, no. 1, pp. 19–30, 2021.
- [13] T. Siddharth, B. S. Kirar, and D. K. Agrawal, "Plant Species Classification Using Transfer Learning by Pretrained Classifier VGG-19," *arXiv Prepr. arXiv2209.03076*, 2022.
- [14] Y. R. Azeez and C. Rajapakse, "An application of transfer learning techniques in identifying herbal plants in sri lanka," in *2019 International Research Conference on Smart Computing and Systems Engineering (SCSE)*, 2019, pp. 172–178.
- [15] T. Akiyama, Y. Kobayashi, Y. Sasaki, K. Sasaki, T. Kawaguchi, and J. Kishigami, "Mobile leaf identification system using CNN applied to plants in Hokkaido," *2019 IEEE 8th Glob. Conf. Consum. Electron. GCCE 2019*, pp. 324–325, 2019, doi: 10.1109/GCCE46687.2019.9015298.
- [16] R. Prabowo, Y. Heningtyas, machudor Yusman, M. Iqbal, and O. D. E. Wulansari, "Klasifikasi Image Tumbuhan Obat (Keji Beling) Menggunakan Artificial Neural Network," *J. Komputasi*, vol. 9, no. 2541–0350, pp. 88–92, 2021, doi: 10.23960/komputasi.v9i2.2868.
- [17] J. Sanjaya and M. Ayub, "Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop, Rotate, dan Mixup," *J. Tek. Inform. dan Sist. Inf.*, vol. 6, no. 2, pp. 311–323, 2020, doi: 10.28932/jutisi.v6i2.2688.
- [18] A. E. Wijaya, W. Swastika, and O. H. Kelana, "Implementasi Transfer Learning Pada Convolutional Neural Network Untuk Diagnosis Covid-19 Dan Pneumonia Pada Citra X-Ray," *Sainsbertek J. Ilm. Sains Teknol.*, vol. 2, no. 1, pp. 10–15, 2021, doi: 10.33479/sb.v2i1.125.
- [19] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016.
- [20] M. Tsiakmaki, G. Kostopoulos, S. Kotsiantis, and O. Ragos, "Transfer learning from deep neural networks for predicting student performance," *Appl. Sci.*, vol. 10, no. 6, 2020, doi: 10.3390/app10062145.
- [21] E. I. Haksoro and A. Setiawan, "Pengenalan Jamur Yang Dapat Dikonsumsi Menggunakan Metode Transfer Learning Pada Convolutional Neural Network," *J. ELTIKOM*, vol. 5, no. 2, pp. 81–91, 2021, doi: 10.31961/eltikom.v5i2.428.
- [22] S. F. Handono, F. T. Anggraeny, and B. Rahmat, "Implementasi Convolutional Neural Network (Cnn) Untuk Deteksi Retinopati Diabetik," *J. Inform. dan Sist. Inf.*, vol. 1, no. 2, pp. 669–678, 2020.
- [23] N. K. Chauhan and K. Singh, "A review on conventional machine learning vs deep learning," *2018 Int. Conf. Comput. Power Commun. Technol. GUCON 2018*, pp. 347–352, 2019, doi: 10.1109/GUCON.2018.8675097.
- [24] P. Kim, *MATLAB deep learning : with machine learning, neural networks and artificial intelligence*. New York: NY: Apress, 2017.
- [25] G. Thiodorus, A. Prasetya, L. A. Ardhani, and N. Yudistira, "Klasifikasi citra makanan/non makanan menggunakan metode Transfer Learning dengan model Residual Network," *Teknologi*, vol. 11, no. 2, pp. 74–83, 2021, doi: 10.26594/teknologi.v11i2.2402.
- [26] M. A. Wani, F. A. Bhat, S. Afzal, and A. I. Khan, *Advances in Deep Learning*, vol. 57, 2019.
- [27] S. O. Oppong, F. Twum, J. Ben Hayfron-Acquah, and Y. M. Missah, "A Novel Computer Vision Model for Medicinal Plant Identification Using Log-Gabor Filters and Deep Learning Algorithms," *Comput. Intell. Neurosci.*, vol. 2022, 2022, doi: 10.1155/2022/1189509.