

Comparison of Deep Learning Architectures in Identifying Types of Medicinal Plant Leaf Images

Sarah Salsabila ^{1*}, Aries Suharso ^{2*}, Purwantoro ^{3*}

* Informatika, Universitas Singaperbangsa Karawang

1910631170136@student.unsika.ac.id ¹, aries.suharso@unsika.ac.id ², purwantoro.masbro@staff.unsika.c.id ³

Article Info

Article history:

Received 2023-08-15

Revised 2024-04-03

Accepted 2024-05-15

Keyword:

Deep Learning,
Image Classification,
Medicinal Plants,
Performance Comparison,
Transfer Learning

ABSTRACT

This study focuses on the identification of 3500 images of medicinal plant leaves using Deep Learning CNN Transfer Learning models such as MobileNet, VGG16, DenseNet121, ResNet50V2, and NASNetMobile. The dataset used is the "Indonesian Herb Leaf Dataset 3500," consisting of 10 classes of medicinal plants. This research has the potential to efficiently and accurately recognize medicinal plants using machine learning workflow methods. The objective of this study is to compare the performance of these five methods in conducting plant identification. The testing phase involves various data handling schemes, dividing the data into two scenarios: 80:10:10 and 70:20:10. Performance comparison is also done between augmented and non-augmented data. The research findings indicate that MobileNet exhibits the best performance with an accuracy, precision, recall, and f1-Score of 98.86%. Accurate leaf identification supports further research on the properties and benefits of medicinal plants and can be applied in the development of decision support systems for plant recognition.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Daun menjadi ciri khas yang mudah dibedakan pada setiap jenis tumbuhan. Bentuk, warna, dan tekstur daun dapat digunakan untuk mengukur daun sebagai data kuantitatif untuk mengidentifikasi jenis tanaman herbal. Karakteristik daun lainnya seperti ukuran, bentuk ujung, pangkal, dan tepi daun, serta jumlah urat daun juga dapat menjadi ciri khas bagi suatu jenis tumbuhan [1].

Namun dibalik mudahnya tumbuhan dikenali dari daunnya, karena ciri-ciri tersebut selalu ada kasus di mana tumbuhan memiliki kesamaan, terutama di tingkat famili, membuat proses identifikasi menjadi sulit bahkan bagi ahli botani berpengalaman sekalipun [2]. Mengidentifikasi tanaman obat secara manual membutuhkan pengetahuan dan keterampilan manusia yang melibatkan banyak proses. Proses ini sering kali memakan waktu dan cukup melelahkan. Saat melakukan identifikasi kesalahan dalam menentukan jenis tanaman obat dapat berakibat fatal bagi penggunaannya salah satunya adalah keracunan [3].

Salah satu solusi permasalahan untuk dapat mengklasifikasikan berbagai jenis tanaman obat secara efektif dan akurat dengan tujuan membantu orang-orang yang tidak memiliki keahlian dalam mengidentifikasi jenis tanaman obat tersebut adalah dengan melakukan identifikasi awal yang memanfaatkan teknologi *image classification* menggunakan *deep learning* dengan objek citra daun tanaman obat sehingga dapat membantu mempercepat proses identifikasi jenis tanaman obat berdasarkan citra tersebut [4].

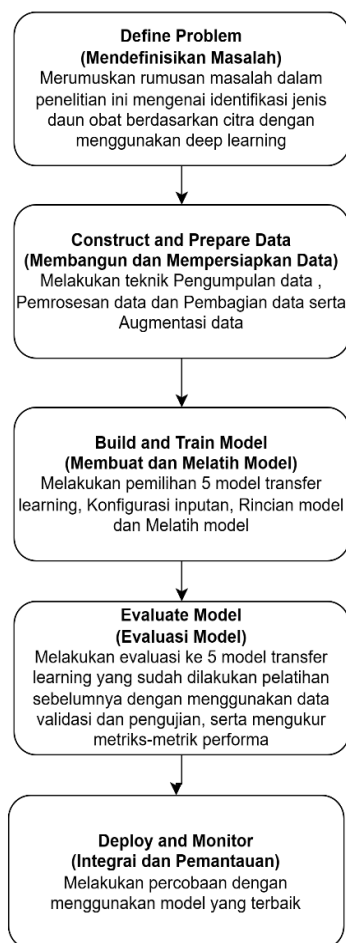
Penelitian mengenai identifikasi citra menggunakan *deep learning* dengan arsitektur CNN sudah banyak dilakukan, salah satunya penelitian oleh [5] pada 4317 data gambar terbagi menjadi 5 kelas. Dilakukan pengklasifikasian dengan 2 skenario. Dimana pada skenario 1, peneliti menggunakan arsitektur yang dirancang sendiri. Didapatkan akurasi mencapai 0.62% dan *loss* akurasi 2.5 (*overfitting*). Lalu skenario kedua menggunakan *Transfer learning* VGG16 dalam iterasi 50 *epoch* didapatkan hasil 0.8 untuk akurasinya dan 0.52 untuk nilai *loss* nya. Ini menunjukkan bahwa arsitektur pada skenario 2 yang menggunakan *transfer*

learning menghasilkan hasil klasifikasi yang lebih baik pada penelitian ini. Lalu penelitian berjudul “A Combination of Transfer Learning and Deep Learning for Medicinal Plant Classification” Penelitian ini menggunakan 2300 sampel dataset tanaman obat yang dibagi kedalam 10 kelas. Menggunakan arsitektur *MobileNet*, dengan rasio pembagian dataset 8:1:1, akurasi adalah 98.7% pada data *test* dan memiliki akurasi rendah di angka 93.2% [6].

Berdasarkan pembahasan tersebut, diketahui bahwa penggunaan *transfer learning* memiliki kinerja yang baik dalam melakukan klasifikasi data citra. Untuk itu penelitian saat ini peneliti akan menerapkan *transfer learning* dengan 5 model yaitu *MobileNet*, *VGG16*, *DenseNet121*, *Resnet50V2*, dan *NasNet Mobile* yang dimana nantinya akan dilakukan komparasi untuk melihat performa terbaik dari kelima model tersebut pada data citra daun tanaman obat.

II. METODE PENELITIAN

Penelitian ini dimulai dengan mengidentifikasi permasalahan yang akan diselesaikan, diikuti oleh tahap pengumpulan data menggunakan teknik pengumpulan data sekunder.




Gambar 1 Rancangan Penelitian

Dataset yang digunakan akan melewati serangkaian langkah pre-processing dan augmentasi sebelum dilakukan tahap pelatihan. Dataset akan diperlakukan dalam proses pelatihan dengan berbagai arsitektur transfer learning yang beragam, termasuk *MobileNet*, *VGG16*, *ResNet50V2*, *DenseNet121*, dan *NasNetMobile*. Setiap model akan dievaluasi berdasarkan hasil training loss, training accuracy, validation loss, validation accuracy, serta confusion matrix. Model terbaik yang dihasilkan akan diuji lebih lanjut untuk keperluan identifikasi. Analisis mendalam akan dilakukan pada hasil evaluasi semua model terhadap dataset, dengan tujuan untuk perbandingan dan analisis menyeluruh [7]. Hasil akhir dari penelitian ini akan mengungkapkan identifikasi terbaik dalam hal arsitektur Transfer Learning. Rancangan keseluruhan proses penelitian ini diilustrasikan dalam Gambar 1.

A. Dataset

Penelitian ini memanfaatkan kumpulan data yang bersifat open source atau publik yang terdiri dari gambar-gambar citra daun tanaman obat. Data ini diambil dari sumber yang bernama Mendeley Data, yang dapat diakses melalui dataset berjudul "Indonesian Herb Leaf Dataset 3500." [7] Dataset ini resmi diperkenalkan pada tanggal 27 Januari 2022, dengan format gambar dalam ekstensi JPG. Dataset tersebut terdiri dari sebanyak 3500 gambar, yang telah dikelompokkan ke dalam 10 kelas berbeda, termasuk kelas *Averrhoa bilimbi* (*Belimbing Wuluh*), *Aloe vera* (*Lidah Buaya*), *Artocarpus heterophyllus* (*Nangka*), *Apium graveolens* (*Seledri*), *Carica papaya* (*Pepaya*), *Citrus Aurantiifolia* (*Jeruk Nipis*), *Ocimum Africanum* (*Kemangi*), *Psidium guajava* (*Jambu Biji*), *Pandanus Amaryllifolius* (*Pandan*), dan *Piper Betle* (*Sirih*). Contoh dari dataset dapat dilihat pada Gambar 2.



Gambar 2 Sample data dari dataset

Pemilihan data telah melalui proses seleksi data untuk memastikan kualitas dan relevansi data yang digunakan dalam penelitian ini. Dataset yang terpilih merupakan dataset yang memiliki karakteristik yang sesuai dengan tujuan penelitian ini, seperti citra daun tanaman obat dengan variasi yang cukup, kualitas gambar yang baik dan metadata yang mencakup informasi penting setiap citra. Data yang digunakan adalah gambar daun tanaman obat tergantung dari jenisnya masing – masing. Informasi mengenai Dataset dapat dilihat pada Tabel 1.

TABEL I
INFORMASI SEPUTAR DATASET

No	Nama Tanaman	Nama Latin	Dimensi	Jumlah
1	Belimbing Wuluh	Averrhoa bilimbi L	1600 x 1200	350
2	Jambu Biji	Psidium Guajava	1600 x 1200	350
3	Jeruk Nipis	Citrus Aurantiifolia	1600 x 1200	350
4	Kemangi	Ocimum Africanum	1600 x 1200	350
5	Lidah Buaya	Aloe vera	1600 x 1200	350
6	Nangka	Artocarpus heterophyllus	1600 x 1200	350
7	Pandan	Pandanus Amaryllifolius	1600 x 1200	350
8	Pepaya	Carica papaya	1600 x 1200	350
9	Seledri	Apium graveolens	1600 x 1200	350
10	Sirih	Piper Betle	1600 x 1200	350

B. Data Preprocessing

Proses pra-pemrosesan data berfungsi sebagai langkah awal untuk menyiapkan gambar-gambar yang akan digunakan sebelum memasuki tahap klasifikasi citra. Dalam rangkaian penelitian ini, langkah preprocessing melibatkan beberapa aspek. Pertama, ukuran gambar pada setiap dataset diubah menjadi 224x224 piksel. Kemudian, pada masing-masing dataset, dilakukan augmentasi data. Teknik augmentasi gambar yang diterapkan dalam penelitian ini mencakup rescale dengan faktor 1/255, shear_range sebesar 0.3, zoom_range sebesar 0.3, rotation_range sebesar 30 derajat, horizontal_flip yang diatur sebagai benar, vertical_flip yang diatur sebagai benar, serta fill_mode yang disetel sebagai 'nearest'.

TABEL 2
SKEMA PELATIHAN MODEL

Skema	Split Data	Train data	Validation Data	Test Data
No Augmentasi	80:10:10 (A)	2800	350	350
Augmentasi	80:10:10 (A)	2800	350	350
No Augmentasi	70:20:10 (B)	2450	700	350
Augmentasi	70:20:10 (B)	2450	700	350

Langkah berikutnya adalah membagi data. Dalam tahap ini, data akan dibagi menjadi tiga bagian, yaitu data latih, data validasi, dan data pengujian. Dua skema pembagian data yang akan digunakan adalah dengan perbandingan 80:10:10 dan 70:20:10. Pada setiap skema pembagian data, dilakukan pelatihan dengan augmentasi dan tanpa augmentasi. Dengan demikian, total empat skema akan dijalankan. Skema pertama adalah data A dengan perbandingan 80:10:10 yang akan melibatkan pelatihan dengan augmentasi dan tanpa augmentasi. Skema kedua adalah data B dengan perbandingan 70:20:10, juga dengan pelatihan augmentasi dan tanpa augmentasi. Detail mengenai empat skema ini dapat dilihat pada Tabel 2.

C. Model Architecture

Penelitian ini menerapkan pendekatan Transfer Learning dalam merancang model yang diusulkan. Struktur arsitektur model yang digunakan mencakup penggunaan beberapa model yang telah terlatih sebelumnya, yaitu MobileNet, VGG16, ResNet50V2, DenseNet121, dan NasNetMobile. Dalam kerangka ini, ditambahkan langkah-langkah tertentu seperti menambahkan layer GlobalAveragePooling2D diikuti oleh penggunaan layer Flatten dan lapisan Dense dengan 10 neuron, serta menggunakan fungsi aktivasi softmax. Optimizer yang digunakan adalah Adam dengan batch size sebanyak 8. Untuk evaluasi kinerja, metode Loss yang digunakan adalah "categorical_crossentropy" dan ukuran metrik yang dihitung adalah akurasi. Pelatihan dilakukan dalam 10 epoch. Arsitektur model yang diimplementasikan dalam model yang diusulkan ini memiliki tingkat kompleksitas yang lebih tinggi dibandingkan dengan model yang digunakan dalam penelitian sebelumnya.

D. Convolutional Neural Network

Convolutional neural network atau biasa disebut CNN, merupakan salah satu deskriptor fitur gambar terbaik dalam bidang *machine learning* dan *computer vision*. Ekstraksi fitur menggunakan CNN terbukti sangat kuat, beberapa peneliti telah memanfaatkan CNN sebagai sebuah ekstraksi fitur dalam berbagai aplikasi. Metode *deep learning* yang memiliki hasil kinerja performa yang paling signifikan dalam pengenalan gambar adalah CNN.[8]

E. Transfer Learning

Transfer learning bertujuan untuk meningkatkan performa pembelajaran target dengan menggunakan sumber data lain yang terkait. [9] Merupakan sebuah proses dimana menggunakan lagi atau ulang *model pre-trained* yang sudah pernah digunakan untuk dilatih sebelumnya. Kejadian ini biasa terjadi pada saat membuat model klasifikasi namun memiliki kendala seperti jumlah dataset yang terbatas. Selain untuk meningkatkan performa, *transfer learning* juga bertujuan untuk mempersingkat atau mengurangi ukuran data pelatihan, waktu yang digunakan untuk pelatihan juga biaya komputasi pada saat mengimplementasikan *model deep learning*. [10]

F. MobileNet

MobileNet adalah sebuah model *efficient* yang dirancang untuk dikembangkan pada aplikasi *mobile*. Dimana fokus utama dalam arsitektur ini adalah latensi dengan menggunakan jaringan yang kecil namun mampu menggunakan kecepatan yang optimal [11].


G. VGG16

Visual *Geometry Group* atau VGG mengeksplorasi efek dari peningkatan kedalaman jaringan konvolusi pada tingkat akurasi pada tahun 2015 lalu. Dimana mereka menggunakan arsitektur dengan ukuran konvolusi yang kecil yaitu 3x3 yang ternyata menghasilkan hasil peningkatan yang *significant* dibandingkan dengan penemuan yang terdahulu. Hasil

penemuan ini diajukan pada *ImageNet Challenge* pada tahun 2014. Dengan sebuah arsitektur yang memiliki total 16 layer. Dimana 13 layer terdiri dari *layer convolutional*, lalu terdapat *max pooling layer* dengan lapisan berukuran 2x2 sebanyak 5 lapisan. Dan juga terdapat 3 lapisan yang terhubung setelah *max pooling* terakhir yaitu lapisan *fully connected layer* dan juga *classifier layer*. Oleh sebab itu model arsitektur ini disebut VGG16.[12]

H. DenseNet121

DenseNet atau *Densely Connected Convolutional Network* adalah sebuah arsitektur yang sudah dilatih pada data besar sebelumnya, seperti data *imagenet*, data CIFAR dan lain-lain. *DenseNet* memiliki beberapa keunggulan yaitu dapat mengurangi masalah penurunan gradien pada saat pelatihan, mendorong kembali penggunaan fitur, memperkuat propagasi fitur serta parameter yang digunakan lebih sedikit dibandingkan dengan *pre trained* model lainnya. [13]



Gambar 3. Arsitektur DenseNet121

I. ResNet 50 V2

ResNet adalah salah satu arsitektur klasifikasi gambar paling populer [14]. Diluncurkan oleh *microsoft* pada tahun 2015 silam. Memiliki kepanjangan yaitu *Residual Neural Network*. Menggunakan pendekatan jaringan syaraf tiruan yang lebih dalam supaya proses *train* model berjalan secara

efektif. Di dalam kompetisi *ImageNet* yang diselenggarakan pada tahun 2015, arsitektur *ResNet* berhasil menempati juara 1. Kelebihan utama dari *ResNet* adalah meningkatnya akurasi klasifikasi tanpa menambah kompleksitas model.

J. NasNet Mobile

NasNet merupakan sebuah arsitektur yang di kembangkan oleh google pada 2017 lalu. Dimana pendekatan yang dilakukan adalah menggunakan *reinforce learning*. *NasNet Mobile* memiliki jumlah parameter yang lebih sedikit yaitu 53,26,716 parameters dibandingkan dengan *NasNet Large* [15]. Awal mula ide arsitektur ini adalah dari penggunaan *framework neural architecture search* (NAS) sebagai sebuah metode *search* yang digunakan untuk mencari kontribusi desain *search space* baru yang dinamakan *NasNet search space*, lalu arsitektur itu di *transfer* ke dataset yang lebih besar. Nah dari *nasnet space search* itulah ditemukan arsitektur terbaik yang kemudian dinamai *NASNet*. Terdapat dua *convolutional cell* dalam *NASNet Mobile* yaitu *Normal Cell* dan *Reduction Cell*. *Normal cell* memiliki fungsi mengembalikan *feature map* dimana tinggi dan lebar peta fitur dikurangi dengan faktor dua [16].

III. HASIL DAN PEMBAHASAN

Setelah menyelesaikan proses pelatihan dan pengujian model pada langkah sebelumnya serta memperoleh data latihan dan pengujian dari masing-masing skenario, langkah selanjutnya adalah melakukan visualisasi data dan melakukan analisis guna menentukan arsitektur mana yang menunjukkan kinerja terbaik dalam klasifikasi data.

A. Analisa Hasil Pelatihan

Berikut data hasil proses pelatihan dari setiap skema sebagai berikut.

1) Hasil Pelatihan Skema 1

TABEL 3
HASIL PELATIHAN SKEMA 1 BERDASARKAN EPOCH

Skema 1										
Metode	Accuracy					Validation Accuracy				
	Epoch					Epoch				
	2	4	6	8	10	2	4	6	8	10
Mobile Net	0.9650	0.9886	0.9946	0.9989	0.9993	0.97143	0.98857	0.9886	0.9886	0.9886
VGG16	0.8071	0.8675	0.8950	0.9075	0.9239	0.7857	0.8800	0.8914	0.9057	0.9171
ResNet50V2	0.9682	0.9900	0.9989	1.000	1.000	0.9600	0.9714	0.9743	0.9714	0.9771
DenseNet121	0.9493	0.9743	0.9836	0.9914	0.9950	0.9657	0.9743	0.9800	0.9857	0.9886
NASNetMobile	0.9229	0.9596	0.9750	0.9818	0.9879	0.9400	0.9400	0.9571	0.9486	0.9657
Metode	Loss					Validation loss				
	Epoch					Epoch				
	2	4	6	8	10	2	4	6	8	10
Mobile Net	0.1387	0.0570	0.0327	0.0198	0.0133	0.1018	0.0606	0.0535	0.0425	0.0412
VGG16	1.1538	0.7341	0.5564	0.4562	0.3878	0.9979	0.6755	0.5436	0.4466	0.3916
ResNet50V2	0.1181	0.0426	0.0186	0.0102	0.0063	0.1068	0.0988	0.0950	0.0919	0.0839
DenseNet121	0.2210	0.1106	0.0738	0.0491	0.0369	0.1803	0.1154	0.0845	0.0742	0.0633
NASNetMobile	0.2968	0.1594	0.1093	0.0802	0.0623	0.2524	0.1884	0.1589	0.1433	0.1092

Berdasarkan analisis table 3 hasil pelatihan data berdasarkan *epoch*-nya pun dari ketiga metode yang memiliki akurasi tertinggi dan hasil yang berselisih sedikit terlihat bahwa *MobileNet* memiliki perkembangan performa yang paling stabil baik dari perubahan akurasi dan juga *loss* nya. Untuk *VGG16* terlihat bahwa model mengalami *overfitting*

dikarenakan perbandingan hasil *training* untuk akurasi dan val akurasi yang cukup tidak seimbang. Proses *training* pada model *mobilenet* di skenario ini diperoleh nilai val akurasi tertinggi di 99% pada *epoch* ke-5 dari total 10 *epoch* pada proses *training*.

2) Hasil Pelatihan Skema 2

TABEL 4
HASIL PELATIHAN SKEMA 2 BERDASARKAN EPOCH

Skema 2										
Metode	Accuracy					Validation Accuracy				
	Epoch					Epoch				
	2	4	6	8	10	2	4	6	8	10
Mobile Net	0.9494	0.9686	0.9729	0.9771	0.9818	0.9400	0.9600	0.9657	0.9714	0.9800
VGG16	0.7300	0.8075	0.8411	0.8621	0.8714	0.7943	0.8229	0.8114	0.8571	0.8800
ResNet50V2	0.9361	0.9532	0.9650	0.9736	0.9761	0.9457	0.9486	0.9571	0.9400	0.9657
DenseNet121	0.9286	0.9561	0.9625	0.9729	0.9732	0.9457	0.9571	0.9486	0.9571	0.9686
NASNetMobile	0.8896	0.9254	0.9386	0.9479	0.9529	0.9057	0.9229	0.9200	0.9457	0.9400
Metode	Loss					Validation loss				
	Epoch					Epoch				
	2	4	6	8	10	2	4	6	8	10
Mobile Net	0.2071	0.1202	0.0875	0.0730	0.0609	0.1831	0.1001	0.1058	0.0940	0.0762
VGG16	1.2654	0.8835	0.7051	0.5969	0.5288	1.0900	0.8098	0.6821	0.5902	0.5099
ResNet50V2	0.2048	0.1403	0.1131	0.0853	0.0740	0.1928	0.1453	0.1199	0.1375	0.1146
DenseNet121	0.2916	0.1750	0.1341	0.1037	0.0932	0.2440	0.1769	0.1705	0.1180	0.1052
NASNetMobile	0.3833	0.2461	0.2016	0.1674	0.1491	0.3011	0.2380	0.2159	0.1707	0.1699

Pada table 4 bahwa performa *MobileNet* memiliki akurasi yang lebih tinggi dibandingkan dengan metode lainnya pada setiap *epoch*. *VGG16* memiliki akurasi yang paling rendah sementara *ResNet50v2*, *DenseNet121* dan *NASNet Mobile* memiliki performa yang hampir serupa. Dan dari berjalannya

pelatihan pada setiap epoch sampai *epoch* ke-10 menunjukkan hasil bahwa beberapa metode telah mencapai tingkat konvergensi yang baik, kecuali *VGG16* dan *DenseNet121* yang mungkin belum sepenuhnya mengalami konvergen.

3) Hasil Pelatihan Skema 3

TABEL 5
HASIL PELATIHAN SKEMA 3 BERDASARKAN EPOCH

Skema 3										
Metode	Accuracy					Validation Accuracy				
	Epoch					Epoch				
	2	4	6	8	10	2	4	6	8	10
Mobile Net	0.9633	0.9886	0.9959	0.9971	0.9996	0.9743	0.9771	0.9886	0.9857	0.9914
VGG16	0.7971	0.8686	0.8992	0.9037	0.9155	0.8557	0.8943	0.9000	0.9129	0.9200
ResNet50V2	0.9649	0.9902	0.9996	1.0000	1.0000	0.9686	0.9729	0.9729	0.9814	0.9814
DenseNet121	0.9539	0.9739	0.9845	0.9935	0.9918	0.9586	0.9757	0.9829	0.9786	0.9871
NASNetMobile	0.9180	0.9571	0.9747	0.9816	0.9861	0.9257	0.9486	0.9514	0.9557	0.9557
Metode	Loss					Validation loss				
	Epoch					Epoch				
	2	4	6	8	10	2	4	6	8	10
Mobile Net	0.1583	0.0670	0.0374	0.0237	0.0150	0.1083	0.0776	0.0511	0.0462	0.0350
VGG16	1.2214	0.7893	0.6026	0.4967	0.4255	1.0307	0.7095	0.5512	0.4654	0.4089
ResNet50V2	0.1297	0.0513	0.0217	0.0127	0.0082	0.1088	0.0861	0.0719	0.0646	0.0594
DenseNet121	0.2269	0.1208	0.0785	0.0533	0.0410	0.1745	0.1022	0.0849	0.0737	0.0577
NASNetMobile	0.3172	0.1731	0.1184	0.0881	0.0668	0.2792	0.2211	0.1646	0.1397	0.1356

Berdasarkan tabel dapat terlihat jelas bahwasannya metode ResNet50V2 mampu mencapai akurasi 1.0000 pada *epoch* ke-6 ini berarti mampu mencapai *epoch* tertinggi dengan waktu tercepat dibanding metode lain pada skema 3. *Mobile Net* dan *DenseNet121* juga mengalami akurasi yang tinggi sedangkan *NASNet Mobile* dan VGG16 memiliki akurasi

yang lebih rendah. Pada beberapa metode seperti *MobileNet*, *VGG16* dan *DenseNet121*, akurasi cenderung meningkat secara stabil dan konvergen. Sementara untuk metode *ResNet50V2* dan *NASNet Mobile* karena pada *epoch* awal – awal sudah mencapai akurasi yang tinggi sehingga tidak terlalu banyak perubahan pada *epoch* terakhir.

4) Hasil Pelatihan Skema 4

TABEL 6
HASIL PELATIHAN SKEMA 4 BERDASARKAN EPOCH

Skema 4										
Metode	Accuracy					Validation Accuracy				
	Epoch					Epoch				
	2	4	6	8	10	2	4	6	8	10
Mobile Net	0.9408	0.9637	0.9678	0.9771	0.9771	0.9543	0.9743	0.9829	0.9729	0.9800
VGG16	0.7012	0.8000	0.8306	0.8482	0.8664	0.7143	0.8200	0.8457	0.8543	0.8600
ResNet50V2	0.9294	0.9531	0.9624	0.9645	0.9702	0.9614	0.9486	0.9529	0.9714	0.9729
DenseNet121	0.9163	0.9429	0.9555	0.9698	0.9690	0.9357	0.9557	0.9600	0.9700	0.9629
NASNetMobile	0.8906	0.9245	0.9347	0.9380	0.9531	0.9114	0.9129	0.9414	0.9286	0.9471
Metode	Loss					Validation loss				
	Epoch					Epoch				
	2	4	6	8	10	2	4	6	8	10
Mobile Net	0.2378	0.1330	0.1034	0.0753	0.0690	0.1780	0.1209	0.0770	0.0861	0.0676
VGG16	1.3170	0.9341	0.7568	0.6469	0.5819	1.1624	0.8423	0.6950	0.6158	0.5451
ResNet50V2	0.2264	0.1516	0.1126	0.1049	0.0917	0.1638	0.1364	0.1407	0.1014	0.0768
DenseNet121	0.3268	0.1971	0.1553	0.1122	0.1055	0.2545	0.1707	0.1425	0.1380	0.1089
NASNetMobile	0.4035	0.2638	0.2121	0.1823	0.1520	0.3216	0.2641	0.1991	0.1840	0.1757

Pada tabel skema 4 terlihat bahwasannya *MobileNet* dan *ResNet50V2* memiliki validasi akurasi yang tinggi seiring dengan peningkatan *epoch*, dimana ini menunjukkan kemampuan untuk melakukan generalisasi dengan baik pada data validasi. *NASNet Mobile* juga mengalami peningkatan yang cukup baik namun lebih lambat dibandingkan dengan *MobileNet*, *ResNet50V2* dan *DenseNet121*. Pada tabel juga terlihat bahwa VGG16 merupakan metode yang masih terus mengalami peningkatan di akurasinya pada *epoch* terakhir

dan penurunan loss pada *epoch-epoch* terakhirnya namun perubahannya lebih lambat dibanding metode- metode lainnya.

B. Analisa Hasil Pengujian

Evaluasi model dalam penelitian ini dilakukan dengan memanfaatkan matriks kebingungan (confusion matrix). Di bawah ini terdapat data hasil pengujian model dari masing-masing skema.

TABEL 7
RATA-RATA PRESISI PADA SELURUH SKEMA

Precision	Skema 1	Skema 2	Skema 3	Skema 4
Mobile Net	98.86%	97.49%	98.30%	98.30%
VGG16	91.23%	89.62%	91%	87.66%
ResNet50V2	97.50%	96.53%	98.33%	98.34%
DenseNet121	96.97%	97.79%	97.46%	97.81%
NASNetMobile	96.71%	97.01%	96.49%	95.06%

TABEL 8
RATA-RATA RECALL PADA SELURUH SKEMA

Recall	Skema 1	Skema 2	Skema 3	Skema 4
Mobile Net	98.86%	97.43%	98.29%	98.29%
VGG16	90.86%	88%	90.29%	85.43%
ResNet50V2	97.43%	96.29%	98.29%	98.29%
DenseNet121	96.86%	97.71%	97.43%	97.71%
NASNetMobile	96.57%	96.86%	96.29%	94.57%

TABEL 9
RATA -RATA F1-SCOREPADA SELURUH SKEMA

F1-Score	Skema 1	Skema 2	Skema 3	Skema 4
Mobile Net	98.86%	97.41%	98.28%	98.28%
VGG16	90.86%	87.99%	90.35%	85.36%
ResNet50V2	97.44%	96.29%	98.29%	98.27%
DenseNet121	96.85%	97.69%	97.41%	97.70%
NASNetMobile	96.56%	96.85%	96.28%	94.56%

TABEL 10
RATA -RATA AKURASI PADA SELURUH SKEMA

Accuracy	Skema 1	Skema 2	Skema 3	Skema 4
Mobile Net	98.86%	97.43%	98.29%	98.29%
VGG16	90.86%	88%	90.29%	85.43%
ResNet50V2	97.43%	96.29%	98.29%	98.29%
DenseNet121	96.86%	97.71%	97.43%	97.71%
NASNetMobile	96.57%	96.86%	96.29%	94.57%

Dari tabel – tabel tersebut didapatkan informasi sebagai berikut :

- 1) Presisi, menunjukkan persentase dari prediksi positif yang benar. Dilihat dari tabel Mobile Net memiliki tingkat presisi tertinggi pada seluruh skema dibandingkan metode lainnya. Skema 1 mobile net mampu mendapatkan persentase keberhasilan 98.86%.
- 2) Recall, menunjukkan persentase dari keseluruhan data positif yang berhasil diprediksi dengan benar. Dilihat dari tabel recall, Mobile Net memiliki tingkat recall tertinggi pada semua skema. Dengan persentase tertinggi 98,86%.
- 3) F1-Score, menunjukkan keseimbangan yang baik antara presisi dan recall. Dimana F1-Score tertinggi juga ditempati oleh metode MobileNet dengan persentase sebesar 98,86%

Berdasarkan informasi – informasi dari *confusion matrix* yang dihasilkan oleh model dan presisi, *recall*, akurasi, dan *F1-Score*. Terdapat 2 model yang memiliki kinerja baik dan tinggi yaitu *MobileNet* dan *ResNet50V2*. Dan dilihat dari tabel rata – rata presisi, *recall*, *F1-Score*, dan akurasi dapat dikatakan pada data evaluasi ini *MobileNet* merupakan model yang memiliki kinerja terbaik.

Selanjutnya dilakukanlah Testing dengan menggunakan data testing untuk seluruh skema yang menggunakan MobileNet. Didapatkan hasil seperti yang ada pada tabel berikut ini.

TABEL 11
HASIL TESTING PADA DATA TESTING

Mobile Net				
	Test Akurasi	Waktu	Test Akurasi Validasi	Waktu
Skema 1	0.982857	11 detik	0.985714	10 detik
Skema 2	0.980000	11 detik	0.988571	21 detik
Skema 3	0.980000	11 detik	0.991428	21 detik
Skema 4	0.985714	10 detik	0.982857	32 detik

Dari tabel 11 tersebut didapatkan informasi bahwa seluruh model *MobileNet* mampu mendapatkan akurasi diatas 98% pada data test. Dari keempat skema. Skema 1 memiliki performa terbaik dilihat dari kecepatan waktu yang dibutuhkan dan hasil yang seimbang antara akurasi dan akurasi validasi. Maka *best model* metode *MobileNet* pada Skema 1 akan digunakan sebagai model untuk melakukan Identifikasi.

TABEL 12
HASIL IDENTIFIKASI PADA DATA TEST

Skema 1	Nama Tanaman	Berhasil	Tidak berhasil	Tingkat keberhasilan
1	Belimbing Wuluh	✓		97%
2	Jambu Biji	✓		99%
3	Jeruk Nipis	✓		93%
4	Kemangi	✓		90%
5	Lidah Buaya	✓		96%
6	Nangka	✓		99%
7	Pandan	✓		99%
8	Pepaya	✓		99%
9	Seledri	✓		99%
10	Sirih	✓		99%

Proses identifikasi dilakukan kepada 10 jenis tanaman obat citra daun dengan menggunakan salah satu gambar yang berada di dalam *data test* yang diambil secara acak.

IV. KESIMPULAN

Penerapan *Deep Learning CNN* dengan menggunakan 5 metode *Transfer learning*, yaitu *MobileNet*, *VGG16*, *DenseNet121*, *Resnet50V2*, dan *NasNet Mobile* ternyata mampu untuk melakukan identifikasi citra pada jenis daun tanaman obat, khususnya pada dataset “*Indonesian Herb Leaf Dataset 3500*”. Berdasarkan hasil evaluasi dari 4 skema yang

telah diatur sedemikian rupa. Dapatkanlah informasi bahwasannya metode MobileNet merupakan metode terbaik yang dapat digunakan untuk melakukan identifikasi citra tanaman obat pada dataset " Indonesian Herb Leaf Dataset 3500" dan model 1 (Mobile Net) pada skema 1 memiliki performa terbaik. Model menghasilkan akurasi sebesar 98% yang artinya model dapat mengidentifikasi dengan benar sebanyak 98% dari total data *testing*. Selain itu nilai rata – rata presisi yang didapatkan sebesar 98,86% yang artinya model mampu mengidentifikasi dengan benar keseluruhan data yang teridentifikasi sebagai true positif.

DAFTAR PUSTAKA

- [1] H.-M. Siregar, S. Wahyuni, dan I. M. Ardaka, "Karakterisasi Morfologi Daun Begonia Alam (Begoniaceae): Prospek Pengembangan Koleksi Tanaman Hias Daun di Kebun Raya Indonesia," 2019.
- [2] K. Saputra S dan M. I. Perangin-Angin, "Klasifikasi Tanaman Obat Berdasarkan Ekstraksi Fitur Morfologi Daun Menggunakan Jaringan Syaraf Tiruan," *Jurnal Informatika*, vol. 5, no. 2, hlm. 169–174, Sep 2018, doi: 10.31311/ji.v5i2.3770.
- [3] R. Pujiati dan N. Rochmawati, "Identifikasi Citra Daun Tanaman Herbal Menggunakan Metode Convolutional Neural Network (CNN)," *Journal of Informatics and Computer Science*, vol. 03, 2022.
- [4] Bella Dwi Mardiana, Wahyu Budi Utomo, Ulfah Nur Oktaviana, Galih Wasis Wicaksono, dan Agus Eko Minarno, "Herbal Leaves Classification Based on Leaf Image Using CNN Architecture Model VGG16," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 1, hlm. 20–26, Feb 2023, doi: 10.29207/resti.v7i1.4550.
- [5] G. Wega Intyanto, "Klasifikasi Citra Bunga dengan Menggunakan Deep Learning: CNN (Convolution Neural Network)," 2021. doi: <https://doi.org/10.19184/jaei.v7i3.28141>.
- [6] N. Duong-Trung, L. Da Quach, M. H. Nguyen, dan C. N. Nguyen, "A combination of transfer learning and deep learning for medicinal plant classification," dalam *ACM International Conference Proceeding Series*, Association for Computing Machinery, 2019, hlm. 83–90. doi: 10.1145/3321454.3321464.
- [7] A. E. Minarno, G. W. Wicaksono, Y. Azhar, dan M. Y. Hasanuddin, "Indonesian Herb Leaf Dataset 3500," *Mendeley Data*, Version 1, 27 Januari 2022.
- [8] J. Pardede, B. Sitohang, S. Akbar, dan M. L. Khodra, "Implementation of Transfer Learning Using VGG16 on Fruit Ripeness Detection," *International Journal of Intelligent Systems and Applications*, vol. 13, no. 2, hlm. 52–61, Apr 2021, doi: 10.5815/ijisa.2021.02.04.
- [9] A. Farahani, B. Pourshojae, K. Rasheed, dan H. R. Arabnia, "A Concise Review of Transfer Learning," Apr 2021, [Daring]. Tersedia pada: <http://arxiv.org/abs/2104.02144>
- [10] L. D. Nguyen, D. Lin, Z. Lin, dan J. Cao, "Deep CNNs for microscopic image classification by exploiting transfer learning and feature concatenation," dalam *Proceedings - IEEE International Symposium on Circuits and Systems*, Institute of Electrical and Electronics Engineers Inc., Apr 2018. doi: 10.1109/ISCAS.2018.8351550.
- [11] Hendriyana dan Y. Hilman Maulana, "Identifikasi Jenis Kayu menggunakan Convolutional Neural Network dengan Arsitektur Mobilenet," *Jurnal Rest*, vol. 4, no. 1, hlm. 70–76, 2020.
- [12] D. Theckedath dan R. R. Sedamkar, "Detecting Affect States Using VGG16, ResNet50 and SE-ResNet50 Networks," *SN Comput Sci*, vol. 1, no. 2, Mar 2020, doi: 10.1007/s42979-020-0114-9.
- [13] A. Abbas, S. Jain, M. Gour, dan S. Vankudothu, "Tomato plant disease detection using transfer learning with C-GAN synthetic images," *Comput Electron Agric*, vol. 187, Agu 2021, doi: 10.1016/j.compag.2021.106279.
- [14] R. Wightman, H. Touvron, dan H. Jégou, "ResNet strikes back: An improved training procedure in timm," Okt 2021, [Daring]. Tersedia pada: <http://arxiv.org/abs/2110.00476>
- [15] K. Radhika, K. Devika, T. Aswathi, P. Sreevidya, V. Sowmya, dan K. P. Soman, "Performance analysis of NASNet on unconstrained ear recognition," dalam *Studies in Computational Intelligence*, Springer, 2020, hlm. 57–82. doi: 10.1007/978-3-030-33820-6_3.
- [16] S. K. Addagarla, "Real Time Multi-Scale Facial Mask Detection and Classification Using Deep Transfer Learning Techniques," *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 9, no. 4, hlm. 4402–4408, Agu 2020, doi: 10.30534/ijatcse/2020/33942020.