

MobileNet untuk Identifikasi Skala Kerapatan dan Transparansi Tajuk Pohon Daun Lebar

Fanirizki Sofiyana¹, Rico Andrian¹, Rahmat Safe'i^{2,*}

¹ Fakultas Matematika dan Ilmu Pengetahuan Alam, Program Studi Ilmu Komputer, Universitas Lampung, Lampung, Indonesia

² Fakultas Pertanian, Program Magister Kehutanan, Universitas Lampung, Lampung, Indonesia

Email: ¹hellofanirizki@gmail.com, ²rico.andrian@fmipa.unila.ac.id, ^{3,*}rahmat.safei@fp.unila.ac.id

Email Penulis Korespondensi: rahmat.safei@fp.unila.ac.id

Abstrak—Kesehatan hutan merupakan aspek penting dalam menjaga keseimbangan lingkungan global. Salah satu metode untuk mengukur kesehatan hutan adalah Forest Health Monitoring (FHM), yang mencakup pengukuran kondisi tajuk (kerapatan dan transparansi tajuk). Pengukuran kerapatan dan transparansi tajuk saat ini dilakukan pakar kesehatan hutan/tenaga ahli dengan membandingkan intensitas sinar matahari di bawah pohon dengan nilai pada kartu skala kemudian mencatatnya. Hal ini kurang efektif karena mengandalkan pengamatan secara langsung dan serta hanya bisa dilakukan oleh tenaga ahli. Teknologi deep learning, khususnya Convolutional Neural Network (CNN) seperti MobileNet, dapat digunakan mempermudah pengukuran ini. Penelitian ini bertujuan untuk identifikasi skala kerapatan dan transparansi tajuk pohon daun lebar. Dataset yang digunakan terdiri dari empat jenis pohon daun lebar: cokelat (*Theobroma cacao*), durian (*Durio zibethinus*), karet (*Havea brasiliensis*), dan kemiri (*Aleurites moluccana*), dengan total 5.000 citra per jenis pohon daun lebar. Preprocessing data dilakukan dengan augmentasi data untuk mempersiapkan dataset. Dataset dibagi menjadi tiga bagian yaitu 70% data train, 10% data val, dan 20% data test. Hasil eksperimen menunjukkan bahwa model MobileNet dapat mengukur kerapatan dan transparansi tajuk dengan akurasi selama pelatihan dan validasi pohon cokelat (94,20%), pohon durian (83,60%), pohon karet (97,80%), dan pohon kemiri (99,20%). Akurasi pada proses pengujian pada pohon cokelat (94,20%), pohon durian (87,50%), pohon karet (97,90%), dan pohon kemiri (98,70%). Hasil ini menunjukkan model MobileNet mampu melakukan identifikasi skala kerapatan dan transparansi tajuk pada metode Forest Health Monitoring (FHM) untuk pohon jenis daun lebar dengan kinerja yang sangat baik. Oleh karena itu, penelitian dengan MobileNet ini menunjukkan potensi penggunaan teknologi deep learning dalam pemantauan kesehatan hutan dengan lebih efektif dan efisien.

Kata Kunci: CNN; Deep Learning; Daun Lebar; FHM; MobileNet

Abstract—Forest health is an essential aspect of maintaining global environmental balance. One method for measuring forest health is Forest Health Monitoring (FHM), which includes measuring crown condition (crown density and foliage transparency). The measurement of crown density and foliage transparency is currently conducted by forest health experts by comparing the intensity of sunlight under the trees with values on a scale card (magic card) and then recording it. This is less effective because it relies on direct observation and can only be done by experts. Deep learning technology, especially Convolutional Neural Networks (CNN) such as MobileNet, can be used to make these measurements easier. This research aims to identify the scale of crown density and foliage transparency of broadleaf tree. This dataset used consist of four broadleaf tree types: cacao (*Theobroma cacao*), durian (*Durio zibethinus*), rubber (*Havea brasiliensis*), and candlenut (*Aleurites moluccana*) with 5,000 images per tree type. The data preprocessing is carried out by data augmentation to prepare the dataset. The dataset is divided into three parts, 70% training data, 10% validation data, and 20% test data. Experimental results show that the MobileNet model can measure crown density and foliage transparency with accuracy during training and validation for *Theobroma cacao* (94.20%), *Durio zibethinus* (83.60%), *Havea brasiliensis* (97.80%), and *Aleurites moluccana* (99.20%). Accuracy in the testing process on *Theobroma cacao* (94.20%), *Durio zibethinus* (87.50%), *Havea brasiliensis* (97.90%), and *Aleurites moluccana* (98.70%). These results show that the MobileNet model is able to identify scales of crown density and foliage transparency using the Forest Health Monitoring (FHM) method for broadleaf trees with very good performance. Therefore, this research with MobileNet shows the potential for using deep learning technology in monitoring forest health more effectively and efficiently. These results show the potential for using deep learning technology in monitoring forest health more effectively and efficiently.

Keywords: CNN; Deep Learning; Broadleaf; FHM; MobileNet

1. PENDAHULUAN

Hutan memberikan berbagai manfaat dalam kehidupan manusia baik secara ekologis, iklim, dan sosial-ekonomi. Kelestarian hutan merupakan aspek kunci dalam menjaga keseimbangan dan harmoni lingkungan global, sehingga diperlukan pemantauan kesehatan hutan. Kesehatan hutan meliputi kemampuan hutan untuk berfungsi secara optimal dalam melindungi air dan tanah, serta menjaga konservasi dan produksi. Metode yang dapat digunakan untuk mengukur kesehatan hutan salah satunya ialah *Forest Health Monitoring* (FHM). FHM memiliki beberapa aspek penilaian, yaitu vitalitas, produktivitas, biodiversitas, dan kualitas tapak [1]. Vitalitas pohon dapat diukur dengan menilai beberapa faktor, di antaranya kerapatan tajuk, transparansi tajuk, rasio tajuk hidup, diameter tajuk, dan mati pucuk [2]. Hutan dikatakan sebagai hutan yang sehat apabila memiliki kerapatan 55% atau lebih, serta transparansi bernilai 45% atau kurang [3]. Kerapatan dan transparansi tajuk pohon dapat diukur dengan cara mengamati sinar matahari yang dapat mencapai lantai hutan [4]. Pengukuran kerapatan dan transparansi tajuk dilakukan pakar kesehatan hutan/tenaga ahli dengan membandingkan intensitas sinar matahari di bawah pohon dengan nilai pada kartu skala kemudian mencatatnya. Hal ini dinilai kurang efektif karena mengandalkan pengamatan secara langsung dan hanya bisa dilakukan oleh tenaga ahli. Teknologi pengolahan citra digital *deep learning* dapat mempermudah pengukuran dan meningkatkan efektivitas kerja sebab dapat dilakukan oleh siapa saja, sehingga biaya yang dikeluarkan pun lebih terjangkau.


Deep learning menggunakan sejumlah besar data untuk memetakan *input* ke label tertentu. Salah satu metode *deep learning* adalah Convolutional Neural Network (CNN). CNN secara umum terdiri atas *convolution layer*, *pooling layer*, dan *fully connected layer* [5]. CNN memiliki arsitektur yang beragam, salah satunya adalah *MobileNet* yang telah dilatih untuk klasifikasi citra menggunakan *dataset ImageNet*. *MobileNet* dengan 28 layer menggunakan konsep *depthwise separable convolution* untuk mengurangi jumlah parameter dan komputasi yang dibutuhkan, sehingga dapat digunakan pada perangkat dengan daya komputasi terbatas seperti perangkat *mobile* dan IoT [6].

Penelitian sebelumnya menggunakan FHM menunjukkan bahwa kondisi kesehatan hutan di Tahura WAR bervariasi, dengan 25% wilayah berkategori sangat baik, 38% berkategori baik, 12% berkategori sedang, dan 25% berkategori sangat buruk [7]. Sedangkan penelitian mengenai *deep learning* yang diterapkan pada metode FHM dilakukan untuk mengidentifikasi tipe kerusakan pohon. Penelitian ini menggunakan dua arsitektur CNN, yaitu *LeNet* dan *MobileNet*. *LeNet* mencapai akurasi 88,99%, sedangkan *MobileNet* mencapai akurasi 99,06% [8].

Penelitian terdahulu telah menunjukkan keberhasilan penggunaan *MobileNet* dalam identifikasi tipe kerusakan pohon pada metode FHM. Namun, model *MobileNet* untuk mengukur skala kerapatan dan transparansi tajuk pohon daun lebar belum pernah dilakukan. Oleh karena itu, penelitian ini bertujuan untuk mengidentifikasi skala kerapatan dan transparansi tajuk pada metode FHM menggunakan *MobileNet* dalam memproses *dataset* tajuk empat jenis pohon daun lebar, sehingga meningkatkan efisiensi kerja dan akurasi pengukuran.

2. METODOLOGI PENELITIAN

Tahapan penelitian, seperti ditunjukkan pada gambar 1, di antaranya ialah pengumpulan *dataset*, pelabelan data, *preprocessing* data, pembagian *dataset*, model CNN *MobileNet*, dan evaluasi model. Pengumpulan *dataset* dilakukan untuk memperoleh data yang akan digunakan pada proses pelatihan model. Pelabelan data dilakukan untuk melabeli tiap data ke dalam kelas kerapatan dan transparansi tajuk sehingga model dapat melakukan tugas klasifikasi berdasarkan *dataset* yang sudah dilabeli. Tahapan *preprocessing* data diterapkan untuk mengatasi permasalahan ketidakseimbangan *dataset* sehingga menghasilkan *dataset* yang seimbang dan lebih beragam. *Dataset* kemudian akan dibagi menjadi data *train*, *val*, dan *test* sehingga proses pelatihan dan pengujian model dilakukan dengan set data yang berbeda. Model CNN *MobileNet* kemudian akan diterapkan pada tiap *dataset* tajuk pohon daun lebar yang telah dilakukan *preprocessing*. Tahapan terakhir yakni evaluasi model berupa analisis dari *confusion matrix*.




Gambar 1. Tahapan Penelitian

2.1 Pengumpulan Dataset

Dataset tajuk pohon daun lebar dari empat jenis pohon dikumpulkan di Tahura WAR Sumber Agung, Bandar Lampung. Pengambilan citra dilakukan dengan kamera Canon EOS 250D dengan pengaturan ISO 100. Citra diambil dengan cara berdiri di bawah pohon dengan jarak 10-20 cm dari batang pohon. Ukuran awal citra adalah 1600×1600 piksel.

2.2 Pelabelan Data

Pelabelan data ini melibatkan 15 responden yang terdiri dari 5 orang dari jurusan Ilmu Komputer dan 10 orang dari jurusan Kehutanan. Responden menilai setiap *dataset* dan mengelompokkannya ke dalam 10 kelas berdasarkan kartu skala kerapatan dan transparansi tajuk, mulai dari 5% hingga 95% seperti ditunjukkan gambar 2. Citra akan dimasukkan ke suatu kelas berdasarkan suara terbanyak. *Dataset* tajuk pohon daun lebar yang telah dikumpulkan dan dilabeli berjumlah 2557 citra. Label kelas diperoleh dari skala kerapatan tajuk (*CD-crown density*) dan transparansi tajuk (*FT-foliage transparency*). Tabel 1 menunjukkan jumlah citra tiap kelasnya.



Gambar 2. Kartu Skala Kerapatan dan Transparansi Tajuk [4]

Tabel 1. Kelas dan jumlah *dataset* pohon daun lebar

Kelas	Jenis Pohon Daun Lebar			
	Cokelat	Durian	Karet	Kemiri
CD5FT95	32	41	78	100
CD15FT85	14	33	69	88
CD25FT75	14	60	75	62
CD35FT65	17	40	62	98
CD45FT55	7	100	48	80
CD55FT45	15	92	35	99
CD65FT35	45	100	60	100
CD75FT25	100	100	15	100
CD85FT15	90	100	23	100
CD95FT5	58	100	7	100
Total Per Jenis Pohon	392	766	472	927
Total				2557

Gambar 3 menunjukkan contoh perbandingan citra tiap kelas kerapatan dan transparansi tajuk pohon daun lebar yakni pohon karet.



Gambar 3. Perbandingan Citra 10 Kelas Kerapatan dan Transparansi Tajuk Pohon Daun Lebar (Karet)

2.3 Preprocessing Data

Data yang telah dikumpulkan dilakukan *preprocessing* terlebih dahulu agar siap digunakan untuk melatih atau menguji model. *Preprocessing* data dilakukan dengan teknik *augmentasi* untuk mengatasi ketidakseimbangan *dataset* dan menghasilkan *dataset* yang lebih besar dan beragam [9]. Ketidakseimbangan dapat menyebabkan bias pada model sebab model cenderung memprediksi kelas mayoritas [10]. Teknik *augmentasi* yang digunakan meliputi *resize*, *vertical flip* dan *horizontal flip*, *random rotation*, *brightness*, serta *zoom* [11]. *Resize* dilakukan dengan mengubah ukuran citra menjadi 224×224 piksel. *Random rotation* dilakukan dengan memutar citra secara acak dengan sudut antara -25° sampai 25° [12].

Augmentasi *brightness* dilakukan dengan meningkatkan kecerahan hingga 50% dari citra asli dan mengurangi kecerahan sebanyak 20% dari citra asli. Citra juga diaugmentasi dengan memperbesarnya hingga 80% dari ukuran aslinya [13]. Setelah augmentasi, jumlah data menjadi 20.000 citra dengan empat jenis daun lebar, sehingga setiap jenis pohon terdiri atas 5.000 citra.

2.4 Pembagian Dataset

Dataset dibagi menjadi data *train*, data *val*, dan data *test*. Data *train* digunakan untuk mencari pola dan hubungan dalam data [5]. Data *val* digunakan untuk mengevaluasi kinerja model pada data yang berbeda dengan data *train* [14]. Data testing digunakan untuk menguji kinerja model [15]. Pembagian data ini dilakukan untuk memastikan bahwa model yang dihasilkan dapat bekerja dengan baik pada data yang belum pernah dilihat sebelumnya. Pembagian data ini dilakukan dengan proporsi 70% untuk data *train*, 10% untuk data *val*, dan 20% untuk data *test* [8]. Data *train* berjumlah 3500 citra pada tiap jenis pohon, data *val* berjumlah 500 citra pada tiap jenis pohon, dan data *test* berjumlah 1000 citra pada tiap jenis pohon.

2.5 Model CNN *MobileNet*

MobileNet adalah arsitektur CNN yang dirancang untuk memaksimalkan akurasi dengan mengurangi beban komputasi. Arsitektur ini memiliki 28 layer yang terdiri dari *input layer*, *convolution layer*, *depthwise separable convolutional layer*, *fully connected layer*, dan *output layer*. *Depthwise separable convolutional* membagi konvolusi menjadi dua tahap, yaitu *depthwise* dan *pointwise*. Hasil dari lapisan terakhir *depthwise separable convolutional* digunakan sebagai *input* untuk *fully connected layer*, sebelum masuk ke *output layer* pada tugas klasifikasi citra [6].

Tabel 2. Base model *MobileNet* [6]

No.	Type	Stride	Filter Shape	Ukuran Input
1	Conv2D	2	3×3×3×32	224×224×3
2	DepthwiseConv2D	1	3×3×32 dw	112×112×32
3	Conv2D	1	1×1×32×64	112×112×32
4	DepthwiseConv2D	2	3×3×64 dw	112×112×64
5	Conv2D	1	1×1×64×128	56×56×64
6	DepthwiseConv2D	2	3×3×128 dw	56×56×128
7	Conv2D	1	1×1×128×128	56×56×128
8	DepthwiseConv2D	2	3×3×128 dw	56×56×128
9	Conv2D	1	1×1×128×256	28×28×128
10	DepthwiseConv2D	2	3×3×256 dw	28×28×256
11	Conv2D	1	1×1×256×256	28×28×256
12	DepthwiseConv2D	2	3×3×256 dw	28×28×256
13	Conv2D	1	1×1×256×512	14×14×256
14	DepthwiseConv2D	1	3×3×512 dw	14×14×512
15	Conv2D	1	1×1×512×512	14×14×512
16	DepthwiseConv2D	1	3×3×512 dw	14×14×512
17	Conv2D	1	1×1×512×512	14×14×512
18	DepthwiseConv2D	1	3×3×512 dw	14×14×512
19	Conv2D	1	1×1×512×512	14×14×512
20	DepthwiseConv2D	1	3×3×512 dw	14×14×512
21	Conv2D	1	1×1×512×512	14×14×512
22	DepthwiseConv2D	2	3×3×512 dw	14×14×512
23	Conv2D	1	1×1×512×1024	7×7×512
24	DepthwiseConv2D	2	3×3×1024 dw	7×7×1024
25	Conv2D	1	1×1×1024×1024	7×7×1024
26	Avg Pool	1	Pool 7×7	7×7×1024
27	FC	1	1024×1000	1×1×1024
28	Softmax	1	Classifier	1×1×1000

Selain itu, model akan dilatih dengan beberapa *hyperparameter* seperti *epoch*, *batch size*, *optimizer*, dan *learning rate* [9]. *Hyperparameter* ini dapat berdampak signifikan pada akurasi, kecepatan, dan stabilitas model [16].

2.6 Evaluasi Model

Model yang telah dilatih akan diuji menggunakan data *test* untuk mengukur kinerjanya. Hasil pengujian dapat dianalisis menggunakan *confusion matrix*. *Confusion matrix* menampilkan jumlah objek yang diklasifikasikan dengan benar dan salah oleh model [9]. Hasil *confusion matrix* dapat dianalisis sehingga mendapatkan nilai analisis statistik seperti: *accuracy*, *precision*, *recall*, dan *f1-score* [17]. Akurasi adalah ukuran seberapa baik model memprediksi kelas yang benar

secara keseluruhan [18]. Perbandingan akurasi dan *loss* model pada data *train* dan data *test* dapat digunakan untuk mengevaluasi kinerja model dan mendeteksi *overfitting*.

3. HASIL DAN PEMBAHASAN

3.1 Model MobileNet

Dataset yang digunakan pada penelitian ini mencakup empat variasi pohon, yakni pohon coklat, durian, karet, dan kemiri, dengan jumlah citra per pohon sebanyak 5000. Dalam melatih masing-masing jenis pohon, digunakan *base* model arsitektur *MobileNet* dengan beberapa konfigurasi yang disesuaikan. Konfigurasi model dilakukan dengan mengatur *hyperparameter* dan beberapa lapisan jaringan tambahan pada model. Pendekatan konfigurasi berbeda-beda untuk setiap *dataset* bertujuan untuk mencapai hasil optimal, sejalan dengan karakteristik khusus dari setiap jenis pohon, termasuk bentuk daun dan struktur kayunya. Untuk menentukan kombinasi *hyperparameter* yang sesuai, dapat memanfaatkan fungsi *callback* seperti *EarlyStopping* untuk menghentikan iterasi pelatihan ketika nilai metrik evaluasi tidak lagi meningkat [19]. Konfigurasi struktur jaringan model dapat dilihat pada tabel 3.

Tabel 3. Struktur Model *MobileNet* Setiap Jenis Pohon

No	Struktur Model			
	Cokelat	Durian	Karet	Kemiri
1	<i>base</i> model <i>MobileNet</i>	<i>base</i> model <i>MobileNet</i>	<i>base</i> model <i>MobileNet</i>	<i>base</i> model <i>MobileNet</i>
2	<i>Conv2D</i>	<i>Conv2D</i>	<i>Conv2D</i>	<i>GlobalAveragePooling D</i>
3	<i>Dense</i> , 128	<i>Dense</i> , 128	<i>Dense</i> , 128	<i>Dense</i> , 10
4	<i>GlobalAveragePooling2D</i>	<i>GlobalAveragePooling2D</i>	<i>GlobalAveragePooling2D</i>	
5	<i>Dense</i> , 10	<i>Dense</i> , 10	<i>Dense</i> , 10	

Konvolusi yang ditambahkan adalah *Conv 2D* dengan filter 32, ukuran *kernel* 3×3, dan fungsi aktivasi *ReLU* [20]. Konvolusi ini bertujuan untuk mengekstraksi fitur tambahan dari data citra. *Dense layer* dengan jumlah unit 128 ditambahkan guna memproses fitur-fitur yang diekstraksi. *GlobalAveragePooling2D* adalah lapisan terakhir yang ditambahkan sebelum *output* [21]. *Dense* terakhir dengan 10 unit dan aktivasi *softmax* digunakan untuk *output* kelas dari model [22]. Model klasifikasi skala kerapatan dan transparansi tajuk pohon daun lebar untuk tiap jenis pohon juga dilatih dengan konfigurasi *hyperparameter* yang ditunjukkan pada tabel 4.


Tabel 4. *Hyperparameter* pada setiap jenis pohon [23]

<i>Hyperparameter</i>	Nilai <i>hyperparameter</i>			
	Cokelat	Durian	Karet	Kemiri
<i>Epoch</i>	16	15	19	14
<i>Batch size</i>	32	64	32	64
<i>Optimizer</i>	Adam	Adam	Adam	Adam
<i>Learning rate</i>	0,001	0,001	0,0001	0,001

Proses pelatihan awalnya direncanakan selama 100 *epoch*, namun berhenti ketika model tidak mengalami kenaikan signifikan selama 5 *epoch* berturut-turut. Hal ini dikarenakan pelatihan menggunakan fungsi *callback EarlyStopping* dengan nilai *patience* 5 [24].

3.2 Evaluasi Model

3.2.1 Model *MobileNet* Pohon Cokelat (*Theobroma cacao*)



Gambar 4. Grafik *accuracy* dan *loss* model *MobileNet* pohon coklat

Grafik pada gambar 4 memperlihatkan akurasi dan *loss* selama proses pelatihan dan validasi. Pada gambar 4a, terlihat model mengalami peningkatan akurasi di awal, kemudian naik perlahan. Proses validasi awalnya fluktuatif, namun naik secara perlahan dari *epoch* ke-10 hingga *epoch* ke-16. Perubahan akurasi selama pelatihan adalah normal karena model sedang beradaptasi dengan data baru. Akurasi mencapai 98,74% pada data *train* dan 94,20% pada data *val*. Gambar 4b menunjukkan bahwa *loss* pada model *MobileNet* pohon cokelat mengalami fluktuasi di awal, lalu stabil dari *epoch* ke-10 hingga ke-16. *Loss* pada pelatihan adalah 3,65%, dan pada validasi adalah 19,47%.

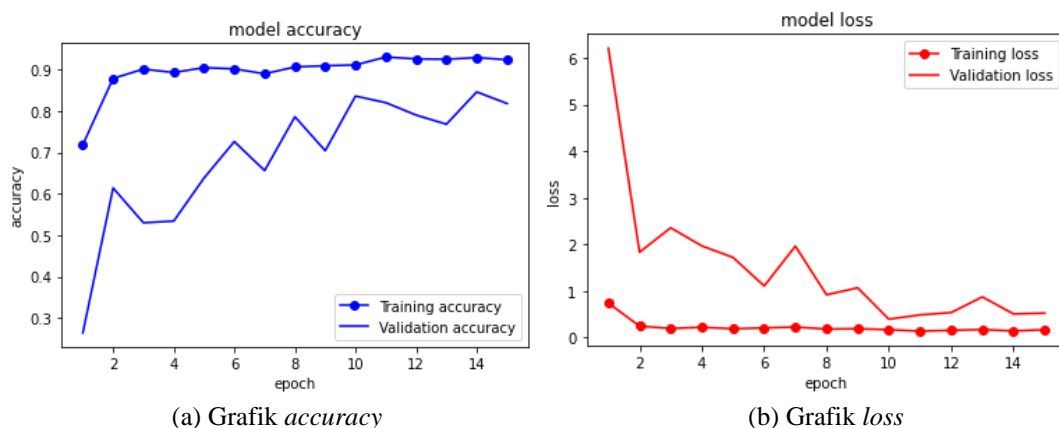
Pengujian model *MobileNet* pohon cokelat dengan data *test* menghasilkan akurasi sebesar 94,20%. Hasil dari pengujian ini direpresentasikan dalam analisis statistik lain seperti *precision*, *recall*, dan *f1-score* yang diperoleh dari perhitungan *confusion matrix*.

Tabel 5. Hasil pengujian model *MobileNet* pohon cokelat

Kelas	<i>Precision</i>	<i>Recall</i>	<i>f1-score</i>
CD5FT95	94,57%	87,00%	90,63%
CD15FT85	84,96%	96,00%	90,14%
CD25FT75	93,14%	95,00%	94,06%
CD35FT65	100,00%	100,00%	100,00%
CD45FT55	97,06%	99,00%	98,02%
CD55FT45	95,74%	90,00%	92,78%
CD65FT35	98,94%	93,00%	95,88%
CD75FT25	90,29%	93,00%	91,63%
CD85FT15	92,78%	90,00%	91,37%
CD95FT5	96,12%	99,00%	97,54%
Rata-rata (<i>macro avg</i>)	94,36%	94,20%	94,20%
Akurasi (<i>accuracy</i>)			94,20%
Error			5,80%

Tabel 5 menunjukkan kinerja model *MobileNet* pohon cokelat yang cukup baik dan konsisten dalam melakukan tugas klasifikasi. Meskipun terdapat kesalahan prediksi pada beberapa kelas, namun nilai akurasi serta rata-rata *precision*, *recall*, dan *f1-score* cukup tinggi. Konsistensi kinerja model dapat diamati dari perbedaan akurasi yang tidak signifikan antara tahap pelatihan dan pengujian. Hal ini menunjukkan bahwa model tetap konsisten dalam berbagai set data yang berbeda. Selain itu, nilai *loss* pada set *val* dan *test* juga relatif rendah dan tidak jauh berbeda dari *loss* pada set *train*. Keberadaan *loss* yang rendah dengan selisih yang kecil menunjukkan bahwa tidak ada tanda-tanda *overfitting* pada model *MobileNet* untuk pohon cokelat. Dengan demikian, model ini mampu melakukan generalisasi dengan baik dari data *train* ke data baru yang belum pernah terlihat sebelumnya.

3.2.2 Model *MobileNet* Pohon Durian (*Durio zibethinus*)



Gambar 5. Grafik *accuracy* dan *loss* model *MobileNet* pohon durian

Grafik akurasi pada gambar 5a menunjukkan bahwa model mengalami peningkatan akurasi yang besar pada awal proses pelatihan, kemudian cenderung stabil. Hal ini menandakan adaptasi model terhadap data. Grafik validasi menunjukkan bahwa model mengalami perubahan naik turun yang cukup signifikan. Akurasi pada data *train* adalah 91,14%, sedangkan pada data *val* adalah 83,60%. *Loss* model mengalami fluktuasi selama pelatihan, dan mencapai nilai terendah pada *epoch* ke-10 seperti ditunjukkan pada gambar 5b. *Loss* pada data *train* adalah 19,15%, sedangkan pada data *val* adalah 39,12%.

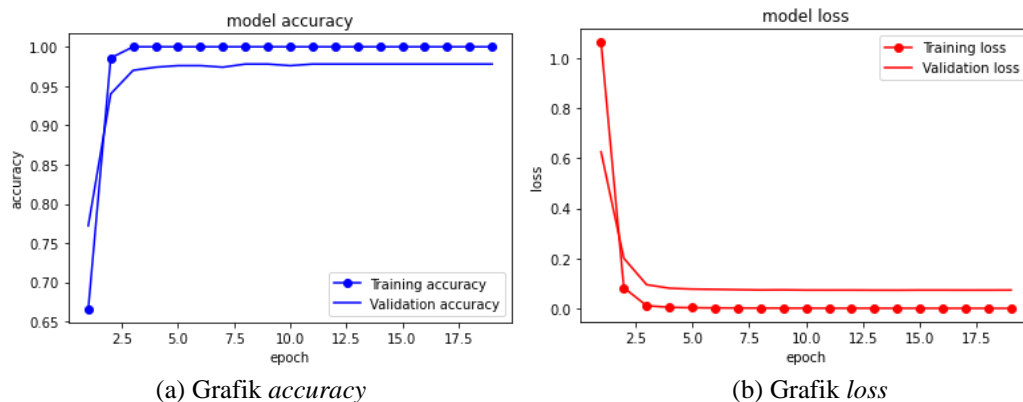
Pengujian model *MobileNet* pohon durian dengan data *test* menghasilkan akurasi sebesar 87,50%. Hasil dari pengujian ini direpresentasikan dalam analisis statistik lain seperti *precision*, *recall*, dan *f1-score* yang diperoleh dari perhitungan *confusion matrix*.

Tabel 6. Hasil pengujian model *MobileNet* pohon durian

Kelas	Precision	Recall	f1-score
CD5FT95	100,00%	100,00%	100,00%
CD15FT85	52,46%	64,00%	57,66%
CD25FT75	54,76%	46,00%	50,00%
CD35FT65	98,91%	91,00%	94,79%
CD45FT55	95,83%	92,00%	93,88%
CD55FT45	98,02%	99,00%	98,51%
CD65FT35	90,91%	100,00%	95,24%
CD75FT25	96,00%	96,00%	96,00%
CD85FT15	92,38%	97,00%	94,63%
CD95FT5	100,00%	90,00%	94,74%
Rata-rata (<i>macro avg</i>)	87,93%	87,50%	87,54%
Akurasi (<i>accuracy</i>)			87,50%
Error			12,50%

Tabel 6 menunjukkan kinerja model *MobileNet* pohon durian yang cukup baik dan konsisten dalam melakukan tugas klasifikasi. Meskipun terdapat kesalahan prediksi pada beberapa kelas, namun nilai akurasi serta rata-rata *precision*, *recall*, dan *f1-score* cukup tinggi. Konsistensi kinerja model dapat diamati dari perbedaan akurasi yang tidak signifikan antara tahap pelatihan dan pengujian. Hal ini menunjukkan bahwa model tetap konsisten dalam berbagai set data yang berbeda. Selain itu, nilai *loss* pada set *val* dan *test* juga relatif rendah dan tidak jauh berbeda dari *loss* pada set *train*. *Loss* yang rendah dengan selisih yang kecil menunjukkan bahwa tidak ada tanda-tanda *overfitting* pada model *MobileNet* untuk pohon durian. Dengan demikian, model ini mampu melakukan generalisasi dengan baik dari data *train* ke data baru yang belum pernah terlihat sebelumnya.

3.2.3 Model *MobileNet* Pohon Karet (*Havea brasiliensis*)



Gambar 6. Grafik *accuracy* dan *loss* model *MobileNet* pohon karet

Model *MobileNet* pohon karet mencapai akurasi 100% pada data *train* dan 97,80% pada data *val*. Model mengalami peningkatan akurasi yang besar pada awal pelatihan dan validasi. Akurasi kemudian stabil dari *epoch* ke-3 sampai *epoch* ke-19 seperti ditunjukkan pada gambar 6a. Walaupun akurasi 100% pada proses pelatihan dapat mengindikasikan *overfitting*, namun akurasi validasi yang tinggi menunjukkan bahwa model tetap efektif dalam kinerjanya pada data baru. Pada gambar 6b, terlihat bahwa *loss* pada model *MobileNet* untuk pohon karet mengalami penurunan drastis di awal, lalu stabil dari *epoch* ke-5 hingga ke-19. *Loss* pada proses pelatihan adalah sebesar 0,04%, dan pada proses validasi adalah 7,25%.

Pengujian model *MobileNet* pohon durian dengan data *test* menghasilkan akurasi sebesar 97,90%. Hasil dari pengujian ini direpresentasikan dalam analisis statistik lain seperti *precision*, *recall*, dan *f1-score* yang diperoleh dari perhitungan *confusion matrix*.

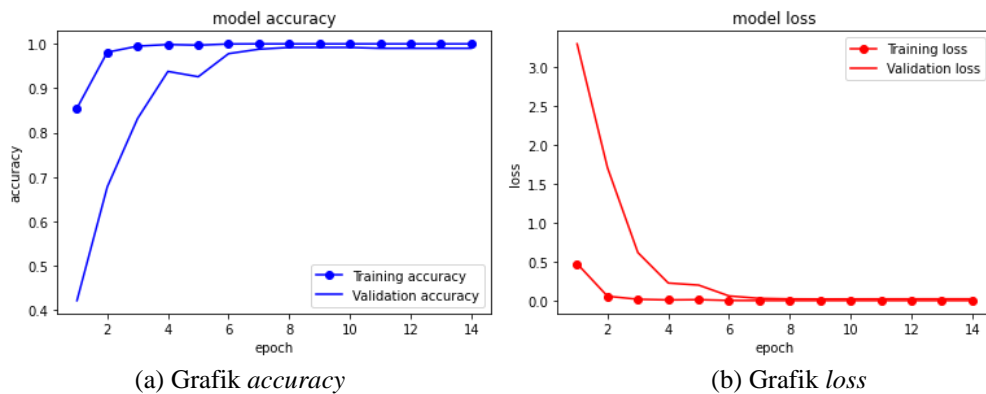
Tabel 7. Hasil pengujian model *MobileNet* pohon Karet

Kelas	Precision	Recall	f1-score
CD5FT95	100,00%	98,00%	98,99%
CD15FT85	97,00%	97,00%	97,00%
CD25FT75	98,99%	98,00%	98,49%
CD35FT65	93,94%	93,00%	93,47%
CD45FT55	95,19%	99,00%	97,06%

CD55FT45	99,01%	100,00%	99,50%
CD65FT35	98,98%	97,00%	97,98%
CD75FT25	99,00%	99,00%	99,00%
CD85FT15	98,99%	98,00%	98,49%
CD95FT5	98,04%	100,00%	99,01%
Rata-rata (<i>macro avg</i>)	97,91%	97,90%	97,90%
Akurasi (<i>accuracy</i>)			97,90%
<i>Error</i>			2,10%

Tabel 7 menunjukkan kinerja model *MobileNet* pohon karet yang cukup baik dan konsisten dalam melakukan tugas klasifikasi citra pohon karet. Hal ini ditunjukkan oleh akurasi yang tinggi dan konsisten, serta *loss* yang rendah pada semua set, yaitu set *train*, *val*, dan *test*. Perbedaan akurasi dan *loss* yang tidak signifikan menunjukkan bahwa model tidak mengalami *overfitting* dan mampu menggeneralisasi dengan sangat baik ke data baru. Selain itu, perolehan nilai rata-rata *precision*, *recall*, dan *f1-score* juga tinggi, menunjukkan kesalahan prediksi yang dilakukan model relatif kecil.

3.2.4 Model *MobileNet* Pohon Kemiri (*Aleurites moluccana*)



Gambar 7. Grafik *accuracy* dan *loss* model *MobileNet* pohon kemiri

Pada gambar 7a, dapat dilihat bahwa model mengalami peningkatan akurasi yang signifikan pada fase awal pelatihan dan validasi. Setelah itu, akurasi cenderung stabil dari *epoch* ke-7 hingga *epoch* ke-14. Model *MobileNet* pohon kemiri mampu memprediksi kelas dengan akurasi mencapai 100% pada proses pelatihan dan 99,20% pada proses validasi. Akurasi pelatihan dan validasi yang tinggi menunjukkan kinerja model yang efektif, baik pada data *train* maupun data baru (data *val*). Grafik *loss* pada gambar 7b menunjukkan penurunan yang signifikan di awal, kemudian stabil pada *epoch* ke-7. Nilai *loss* mencapai 0,01% pada proses pelatihan dan 1,97% pada proses validasi.

Pengujian model *MobileNet* pohon durian dengan data *test* menghasilkan akurasi sebesar 98,70%. Hasil dari pengujian ini direpresentasikan dalam analisis statistik lain seperti *precision*, *recall*, dan *f1-score* yang diperoleh dari perhitungan *confusion matrix*.

Tabel 8. Hasil pengujian model *MobileNet* pohon kemiri

Kelas	<i>Precision</i>	<i>Recall</i>	<i>f1-score</i>
CD5FT95	99,01%	100,00%	99,50%
CD15FT85	100,00%	100,00%	100,00%
CD25FT75	95,15%	98,00%	96,55%
CD35FT65	98,97%	96,00%	97,46%
CD45FT55	98,00%	98,00%	98,00%
CD55FT45	100,00%	99,00%	99,50%
CD65FT35	97,09%	100,00%	98,52%
CD75FT25	100,00%	99,00%	99,50%
CD85FT15	100,00%	97,00%	98,48%
CD95FT5	99,01%	100,00%	99,50%
Rata-rata (<i>macro avg</i>)	98,72%	98,70%	98,70%
Akurasi (<i>accuracy</i>)			98,70%
<i>Error</i>			1,30%

Tabel 8 menunjukkan kinerja model *MobileNet* pohon kemiri yang cukup baik dan konsisten dalam melakukan tugas klasifikasi. Model *MobileNet* pohon kemiri memiliki nilai akurasi yang tinggi pada semua set, yaitu set *train*, *val*, dan *test*. Selain itu, nilai *loss* yang relatif rendah pada semua set dengan perbedaan yang tidak terlalu besar mengindikasikan bahwa model tidak mengalami *overfitting*, sehingga mampu menggeneralisasi dengan sangat baik ke

data baru. Konsistensi tersebut menunjukkan kinerja model yang baik dalam memprediksi kelas citra pohon kemiri. Selain itu, perolehan nilai rata-rata *precision*, *recall*, dan *f1-score* juga tinggi, menunjukkan kesalahan prediksi yang dilakukan model relatif kecil.

4. KESIMPULAN

Hasil identifikasi skala kerapatan dan transparansi tajuk pada metode *Forest Health Monitoring* (FHM) untuk pohon jenis daun lebar menggunakan model *MobileNet* memperlihatkan kinerja yang baik. Hal ini dibuktikan dengan nilai akurasi yang tinggi pada proses pelatihan baik pada set *train* dan set *val*, serta pada set *test*. Nilai akurasi selama pelatihan untuk pohon cokelat (94,20%), pohon durian (83,60%), pohon karet (97,80%), dan pohon kemiri (99,20%). Akurasi pada proses pengujian pada pohon cokelat (94,20%), pohon durian (87,50%), pohon karet (97,90%), dan pohon kemiri (98,70%). Hasil rata-rata *precision* model *MobileNet* untuk pohon cokelat (94,36%), pohon durian (87,93%), pohon karet (97,91%), dan pohon kemiri (98,72%). Hasil rata-rata *recall* model *MobileNet* untuk pohon cokelat (94,20%), pohon durian (87,50%), pohon karet (97,90%), dan pohon kemiri (98,70%). Perolehan nilai rata-rata *precision* dan *recall* yang tinggi menunjukkan kesesuaian model dalam memprediksi setiap kelas. Nilai *loss* yang rendah juga menunjukkan bahwa model dapat mengidentifikasi skala kerapatan dan transparansi tajuk pohon dengan kinerja tinggi.

REFERENCES

- [1] R. Safe'i, A. Darmawan, H. Kaskoyo, and C. F. G. Rezinda, "Analysis of Changes in Forest Health Status Values in Conservation Forest (Case Study: Plant and Animal Collection Blocks in Wan Abdul Rachman Forest Park (Tahura WAR))," *J Phys Conf Ser*, vol. 1842, no. 1, p. 012049, Mar. 2021, doi: 10.1088/1742-6596/1842/1/012049.
- [2] R. Safe'i, C. Wulandari, and H. Kaskoyo, "Assessment of Forest Health in Various Forest Types in Lampung Province," *Jurnal Sylva Lestari*, vol. 7, no. 1, p. 95, Feb. 2019, doi: 10.23960/jsl11795-109.
- [3] D. Pertiwi, R. Safe'i, H. Kaskoyo, and I. Indriyanto, "Identifikasi Tipe Kerusakan Pohon Menggunakan Metode Forest Health Monitoring (FHM)," *PERENNIAL*, vol. 15, no. 1, p. 1, Jul. 2019, doi: 10.24259/perennial.v15i1.6033.
- [4] N. G. Tallent-Halsell, "Forest Health Monitoring 1994 Field Methods Guide, EPA/620/R-94/027," United States Environmental Protection Agency Washington, DC, 1994.
- [5] L. Alzubaidi et al., "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *J Big Data*, vol. 8, no. 1, p. 53, Mar. 2021, doi: 10.1186/s40537-021-00444-8.
- [6] A. G. Howard et al., "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," *CoRR*, vol. abs/1704.04861, 2017.
- [7] D. Pertiwi, R. Safe'i, and H. Kaskoyo, "Kesehatan Hutan di Blok Koleksi Tumbuhan dan/atau Satwa Tahura Wan Abdul Rachman Provinsi Lampung," *Jurnal Hutan Tropis*, vol. 8, no. 3, pp. 244–347, Nov. 2020.
- [8] Z. Nopriyanto, Ri. Andrian, R. Safei, and K. Muludi, "Implementasi Metode CNN Computer Vision Dalam Identifikasi Tipe Kerusakan Pohon Berbasis FHM," *InComTech: Jurnal Telekomunikasi dan Komputer*, vol. 10, no. 1, pp. 15–22, 2022.
- [9] F. J. Moreno-Barea, J. M. Jerez, and L. Franco, "Improving classification accuracy using data augmentation on small data sets," *Expert Syst Appl*, vol. 161, p. 113696, Dec. 2020, doi: 10.1016/j.eswa.2020.113696.
- [10] K. Ghosh, C. Bellinger, R. Corizzo, P. Branco, B. Krawczyk, and N. Japkowicz, "The class imbalance problem in deep learning," *Mach Learn*, Dec. 2022, doi: 10.1007/s10994-022-06268-8.
- [11] V. Verma et al., "A Deep Learning-Based Intelligent Garbage Detection System Using an Unmanned Aerial Vehicle," *Symmetry (Basel)*, vol. 14, no. 5, p. 960, May 2022, doi: 10.3390/sym14050960.
- [12] S. Shafi and A. Assad, "Exploring the Relationship Between Learning Rate, Batch Size, and Epochs in Deep Learning: An Experimental Study," 2023, pp. 201–209. doi: 10.1007/978-981-19-6525-8_16.
- [13] X. Xing, P. Song, K. Zhang, F. Yang, and Y. Dong, "ZooME: Efficient Melanoma Detection Using Zoom-in Attention and Metadata Embedding Deep Neural Network," in 2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), IEEE, Nov. 2021, pp. 4041–4044. doi: 10.1109/EMBC46164.2021.9630452.
- [14] A. E. Maxwell, T. A. Warner, and L. A. Guillén, "Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies—Part 1: Literature Review," *Remote Sens (Basel)*, vol. 13, no. 13, 2021, doi: 10.3390/rs13132450.
- [15] R. Ramadhan, I. Fibriani, and W. Cahyadi, "Penerapan Microexpressions Untuk Mengenali Hubungan Kekerabatan Menggunakan Extreme Learning Machine," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 1, no. 2, pp. 162–169, Dec. 2021, doi: 10.57152/malcom.v1i2.101.
- [16] S. Afaq and S. Rao, "Significance Of Epochs On Training A Neural Network," *International Journal of Scientific & Technology Research*, vol. 9, pp. 485–488, 2020.
- [17] D. Chicco and G. Jurman, "The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation," *BMC Genomics*, vol. 21, no. 1, p. 6, 2020, doi: 10.1186/s12864-019-6413-7.
- [18] M. Grandini, E. Bagli, and G. Visani, "Metrics for Multi-Class Classification: an Overview," Aug. 2020.
- [19] H. Wang, T. Li, Z. Zhuang, T. Chen, H. Liang, and J. Sun, "Early Stopping for Deep Image Prior," Dec. 2021.
- [20] A. H. A. Zargari, M. AshrafiAmiri, M. Seo, S. M. P. Dinakarrao, M. E. Fouda, and F. Kurdahi, "CAPTIVE: Constrained Adversarial Perturbations to Thwart IC Reverse Engineering," Oct. 2021.
- [21] Y. Feng, M. Gao, and Z. Zhang, "Web Service QoS Classification Based on Optimized Convolutional Neural Network," in 2019 IEEE 14th International Conference on Intelligent Systems and Knowledge Engineering (ISKE), IEEE, Nov. 2019, pp. 584–590. doi: 10.1109/ISKE47853.2019.9170368.

- [22] C. Shiranthika, N. Premakumara, H.-L. Chiu, H. Samani, C. Shyalika, and C.-Y. Yang, "Human Activity Recognition Using CNN & LSTM," in 2020 5th International Conference on Information Technology Research (ICITR), IEEE, Dec. 2020, pp. 1–6. doi: 10.1109/ICITR51448.2020.9310792.
- [23] J. N. Mogan, C. P. Lee, K. M. Lim, and K. S. Muthu, "VGG16-MLP: Gait Recognition with Fine-Tuned VGG-16 and Multilayer Perceptron," *Applied Sciences*, vol. 12, no. 15, p. 7639, Jul. 2022, doi: 10.3390/app12157639.
- [24] A. R. Muhammad, H. P. Utomo, P. Hidayatullah, and N. Syakrani, "Early Stopping Effectiveness for YOLOv4," *Journal of Information Systems Engineering and Business Intelligence*, vol. 8, no. 1, pp. 11–20, Apr. 2022, doi: 10.20473/jisebi.8.1.11-20.