

PERBANDINGAN MODEL KLASIFIKASI PENYAKIT DAUN BAKAU MENGGUNAKAN ARSITEKTUR VGG16 DAN MOBILNETV2

I Kadek Prasta Yudhantara^{1*}, Ni Ketut Kertiasih², I Nyoman Saputra Wahyu Wijawa³

^{1,2,3}Program Studi Ilmu Komputer, Universitas Pendidikan Ganesha; 67 Jalan Ahmad Yani 81116

Keywords:

CNN, Penyakit Daun
Bakau, VGG16, MobileNetV2

Correspondent Email:

prasta@undiksha.ac.id

Abstrak. Penelitian ini bertujuan membandingkan kinerja arsitektur *Convolutional Neural Network* (CNN) VGG16 dan MobileNetV2 dalam klasifikasi penyakit daun bakau jenis *Ceriops tagal* berbasis citra digital. Penyakit daun bakau menjadi salah satu faktor utama degradasi ekosistem mangrove karena berdampak langsung pada proses fotosintesis dan pertumbuhan tanaman. Dataset yang digunakan terdiri dari 821 citra daun bakau yang diklasifikasikan ke dalam empat kelas, yaitu daun sehat, bercak putih, bercak hitam, dan daun diserang hama. Kedua model dilatih menggunakan pendekatan transfer learning dengan evaluasi kinerja menerapkan metode *5-Fold Cross Validation* pada dua skenario pelatihan, yaitu *early stopping* dan *50 epoch*. Hasil penelitian menunjukkan bahwa MobileNetV2 dengan skenario *early stopping* memberikan performa terbaik dengan nilai *accuracy* dan macro average recall tertinggi sebesar 0,96 serta performa yang stabil pada seluruh *fold* pengujian. Sebaliknya, VGG16 hanya mencapai *accuracy* maksimum 0,79 pada skenario *early stopping* dan 0,87 pada skenario *50 epoch*, namun menunjukkan variasi performa yang besar antar *fold* serta kecenderungan *overfitting*. Berdasarkan hasil tersebut, MobileNetV2 terbukti lebih andal, efisien, dan memiliki kemampuan generalisasi yang lebih baik dibandingkan VGG16 dalam klasifikasi penyakit daun bakau, sehingga berpotensi diterapkan sebagai sistem deteksi dini penyakit mangrove secara praktis dan berkelanjutan.



Copyright © JITET (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Abstract. This study aims to compare the performance of *Convolutional Neural Network* (CNN) architectures, VGG16 and MobileNetV2, in classifying mangrove leaf diseases of *Ceriops tagal* based on digital images. Mangrove leaf diseases are a major contributing factor to mangrove ecosystem degradation, as they directly affect photosynthesis and plant growth. The dataset used in this research consists of 821 mangrove leaf images classified into four categories: healthy leaves, white spot disease, black spot disease, and pest-attacked leaves. Both models were developed using a transfer learning approach and evaluated using *5-Fold Cross Validation* under two Training scenarios, namely *early stopping* and *50 epochs*. The experimental results indicate that MobileNetV2 with the *early stopping* scenario achieved the best performance, with the highest accuracy and macro average recall of 0.96 and stable results across all folds. In contrast, VGG16 achieved a maximum accuracy of 0.79 under the *early stopping* scenario and 0.87 under the *50-epoch* scenario; however, its performance was inconsistent across folds and showed a strong tendency toward *overfitting*. These findings demonstrate that MobileNetV2 is more reliable, computationally efficient, and exhibits better generalization capability than VGG16 for mangrove leaf disease classification. Therefore,

MobileNetV2 is more suitable for practical implementation in early detection systems to support sustainable mangrove conservation efforts.

1. PENDAHULUAN

Hutan bakau merupakan salah satu ekosistem pesisir yang memiliki peran penting dari aspek ekologis, sosial, dan ekonomi. Secara ekologis, hutan bakau berfungsi sebagai pelindung alami pantai dari abrasi, penyerap karbon, serta habitat bagi berbagai jenis biota laut [1]. Meskipun demikian, dalam dua dekade terakhir luas hutan bakau dunia terus mengalami penurunan. Sekitar 4,3% hutan bakau global telah mengalami degradasi, dengan kurang lebih 40% kerusakan disebabkan oleh faktor alami, termasuk serangan penyakit tanaman [2]. Penyakit yang menyerang daun bakau menjadi salah satu faktor dominan karena daun merupakan bagian tanaman yang paling rentan, sehingga gangguan pada daun dapat berdampak langsung terhadap proses fotosintesis dan pertumbuhan tanaman [3].

Penyakit daun bakau umumnya dipicu oleh infeksi jamur, bakteri, maupun serangan hama, yang secara visual ditandai dengan munculnya bercak putih, bercak hitam, lubang pada daun, serta perubahan warna jaringan daun [4]. Kondisi tersebut berkontribusi terhadap tingginya kegagalan dalam upaya rehabilitasi hutan mangrove [5]. Hingga saat ini, proses identifikasi penyakit daun bakau masih banyak dilakukan secara manual, sehingga memerlukan keahlian khusus, memakan waktu, serta cenderung bersifat subjektif.

Seiring dengan perkembangan teknologi, pendekatan *deep learning*, khususnya *Convolutional Neural Network* (CNN), mulai banyak dimanfaatkan untuk klasifikasi penyakit tanaman berbasis citra digital. Sejumlah penelitian sebelumnya juga menunjukkan keberhasilan penggunaan arsitektur CNN seperti VGG16 dan MobileNetV2 pada berbagai komoditas tanaman, antara lain tomat, padi, singkong, kopi, dan cabai [6][7][8]. Namun demikian, penelitian yang secara khusus mengkaji klasifikasi penyakit daun bakau, terutama pada spesies *Ceriops tagal*, masih relatif terbatas. Selain itu, studi yang

membandingkan kinerja arsitektur CNN dengan kompleksitas berbeda menggunakan metode evaluasi yang ketat juga masih jarang dilakukan.

Berdasarkan kondisi tersebut, penelitian ini bertujuan untuk mengklasifikasikan penyakit daun bakau jenis *Ceriops tagal* menggunakan arsitektur VGG16 dan MobileNetV2, serta membandingkan kinerja kedua model berdasarkan tingkat akurasi dan efisiensi melalui metode *K-Fold Cross Validation*. Hasil penelitian ini diharapkan dapat menjadi dasar pengembangan sistem deteksi dini penyakit daun bakau yang lebih objektif dan andal, guna mendukung upaya konservasi ekosistem mangrove secara berkelanjutan.

2. TINJAUAN PUSTAKA

2.1 Tumbuhan Bakau dan Penyakit Daun

Tumbuhan bakau merupakan komponen penting ekosistem pesisir yang berfungsi sebagai pelindung pantai dari abrasi, penyerap karbon, serta habitat berbagai biota laut [1]. Keberlanjutan hutan bakau sangat dipengaruhi oleh kondisi kesehatan tanaman, khususnya pada bagian daun yang berperan langsung dalam proses fotosintesis. Penyakit daun bakau menjadi ancaman serius karena dapat menurunkan kemampuan fotosintesis dan pertumbuhan tanaman [3]. Penyakit tersebut umumnya disebabkan oleh infeksi jamur, bakteri, serta serangan hama, yang ditandai dengan bercak putih, bercak hitam, lubang daun, dan perubahan warna jaringan [4].

2.2 Deep learning

Deep learning merupakan cabang pembelajaran mesin yang menggunakan jaringan saraf tiruan berlapis banyak untuk mempelajari pola data secara otomatis [9]. Metode ini unggul dalam menangani data tidak terstruktur seperti citra digital tanpa memerlukan ekstraksi fitur manual. Dalam pengolahan citra, *deep learning* mampu mengenali pola visual kompleks dengan tingkat akurasi tinggi, sehingga banyak

digunakan dalam klasifikasi penyakit tanaman [10].

2.3 Convolutional Neural Network (CNN)

Salah satu pendekatan dalam *deep learning* yang secara khusus dikembangkan untuk mengolah data berbentuk citra dan banyak diterapkan pada permasalahan klasifikasi gambar adalah *Convolutional Neural Network* (CNN) [11]. CNN bekerja melalui lapisan konvolusi, aktivasi, *pooling*, dan *fully connected* untuk mengekstraksi fitur visual secara hierarkis [12]. Kemampuan *feature extraction* otomatis menjadikan CNN sangat efektif dalam klasifikasi penyakit daun berbasis citra [13], CNN banyak digunakan dan menjadi salah satu metode paling populer dalam bidang pengenalan atau klasifikasi gambar [14]. CNN beroperasi dengan cara mengambil fitur visual melalui tahapan konvolusi, *pooling*, serta fungsi aktivasi nonlinier yang memungkinkan sistem mengenali pola-pola pada citra secara bertingkat dari tingkat sederhana hingga kompleks [15].

2.4 Arsitektur VGG16

Arsitektur VGG-16 merupakan salah satu model *deep learning* yang tersusun atas total 16 lapisan pemrosesan [16]. VGG16 merupakan arsitektur yang mampu mengekstraksi fitur visual secara mendalam dan menghasilkan akurasi tinggi, namun memiliki jumlah parameter besar sehingga membutuhkan sumber daya komputasi tinggi [17][18].

2.5 MobileNetV2


MobileNetV2 dirancang sebagai arsitektur ringan dengan menggunakan *depthwise separable convolution* dan *inverted residual blocks*, sehingga lebih efisien secara komputasi tanpa penurunan akurasi yang signifikan [19].

2.6 Penelitian Terkait

Berbagai penelitian menunjukkan keberhasilan CNN dalam klasifikasi penyakit daun tanaman. VGG16 terbukti unggul pada klasifikasi daun tomat dan cabai [6][8], sementara MobileNetV2 menunjukkan efisiensi dan performa tinggi pada tanaman padi, singkong, dan kopi [7][20][21].

3. METODE PENELITIAN

Penelitian ini termasuk dalam penelitian kuantitatif karena menitikberatkan pada pengolahan serta analisis data numerik guna menilai kinerja model klasifikasi penyakit daun tanaman bakau. Pendekatan kuantitatif digunakan untuk mengukur variabel penelitian secara objektif melalui data yang bersifat terukur, sehingga hasilnya dapat dianalisis secara sistematis dan statistik. Gambaran penelitiannya bisa dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

3.1 Jenis dan Desain Penelitian

Penelitian ini merupakan penelitian kuantitatif dengan pendekatan eksperimen komputasional. Fokus penelitian adalah pengembangan dan evaluasi model klasifikasi penyakit daun tanaman bakau berbasis citra digital menggunakan metode *deep learning*. Eksperimen dilakukan dengan membandingkan dua arsitektur *Convolutional Neural Network* (CNN), yaitu VGG16 dan MobileNetV2, untuk menentukan model dengan performa terbaik dalam klasifikasi penyakit daun bakau.

3.2 Dataset Penelitian

Dataset yang digunakan berupa citra daun tanaman bakau jenis *Ceriops tagal* yang dikumpulkan melalui dokumentasi langsung di kawasan Taman Nasional Bali Barat. Pengambilan data dilakukan menggunakan kamera ponsel dengan sudut pengambilan dari atas daun. Dataset terdiri dari empat kelas, yaitu daun sehat, bercak putih, bercak hitam, dan daun diserang hama. Proses pelabelan data dilakukan dengan bantuan ahli kehutanan untuk memastikan validitas kelas. Dataset di split menjadi 80/20.

3.3 Pra-pemrosesan Data

Tahap pra-pemrosesan meliputi pemotongan (*cropping*) area daun, penyesuaian ukuran citra

menjadi 224×224 piksel, serta normalisasi nilai piksel ke rentang 0–1. Untuk meningkatkan variasi data dan mencegah *overfitting*, diterapkan teknik data augmentation berupa rotasi, *flipping*, *zoom*, dan penyesuaian pencahayaan. Setelah augmentasi, jumlah data latih meningkat secara signifikan sehingga mendukung proses pembelajaran model.

3.4 Perancangan dan Pelatihan Model

Model VGG16 dan MobileNetV2 digunakan dengan pendekatan *transfer learning* menggunakan bobot awal dari dataset ImageNet. Layer klasifikasi akhir dimodifikasi agar sesuai dengan jumlah kelas penelitian. Proses pelatihan dilakukan menggunakan *optimizer* Adam dan fungsi *loss categorical cross-entropy*. Pelatihan dijalankan dalam beberapa skenario, yaitu *early stopping* dan *epoch* 50.

3.5 Evaluasi Model

Evaluasi kinerja model dilakukan menggunakan metode *5-Fold Cross Validation* untuk memperoleh hasil yang stabil dan representatif. Metrik evaluasi yang digunakan meliputi akurasi, presisi, *recall*, *F1-score*, dan confusion matrix. Hasil evaluasi dari kedua model dibandingkan untuk menentukan arsitektur CNN yang paling efektif dan efisien dalam mengklasifikasikan penyakit daun bakau.

4. HASIL DAN PEMBAHASAN

Pelatihan model dilakukan menggunakan dua arsitektur, yaitu MobileNetV2 dan VGG16. Proses pelatihan menerapkan tiga skenario, meliputi penggunaan *early stopping* dan 50 *epoch*. Evaluasi kinerja model dilakukan menggunakan metode *k-fold cross validation*, di mana hasil terbaik dari setiap *fold* pada masing-masing skenario digunakan sebagai dasar perbandingan.

Pada tahap pengumpulan data didapatkan data mentah sebanyak 821 gambar kemudian data di kelompokkan menjadi 4 kelas seperti pada gambar



Gambar 2. Contoh data daun: (a) bercak putih, (b) bercak hitam. (c) diserang hama, (d) sehat

4.1 Model VGG16

Berdasarkan hasil evaluasi scenario *early stopping*, *fold* ke-4 menunjukkan performa terbaik dengan nilai akurasi dan *macro avg recall* tertinggi, masing-masing sebesar 0,79. Hasil ini mengindikasikan bahwa model VGG16 pada *fold* tersebut mampu memberikan prediksi yang paling akurat sekaligus mempertahankan kemampuan pengenalan yang seimbang pada seluruh kelas penyakit daun bakau. Berikut *classification report Macro avg* skenario *early stopping* ditampilkan pada Tabel 1.

Tabel 1. *Classification report Macro AVG*

<i>Fold</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	0.77	0.79	0.77	0.77
2	0.67	0.68	0.66	0.65
3	0.32	0.16	0.31	0.21
4	0.79	0.81	0.79	0.79
5	0.72	0.80	0.72	0.71

Pelatihan 50 *epoch*, *fold* ke-3 menghasilkan nilai akurasi dan *macro recall* tertinggi, masing-masing sebesar 0,87. Hasil ini mengindikasikan bahwa model VGG16 pada *fold* tersebut memiliki kemampuan klasifikasi terbaik serta mampu mengenali seluruh kelas penyakit daun bakau secara seimbang. Berikut *classification report macro avg* skenario *epoch* 50 ditampilkan pada Tabel 2.

Tabel 2. *Classification report Macro AVG*


<i>Fold</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	0.69	0.70	0.69	0.69
2	0.23	0.08	0.24	0.11
3	0.87	0.89	0.87	0.87
4	0.37	0.25	0.37	0.26
5	0.58	0.58	0.58	0.57

Grafik *accuracy* dan *loss fold 4* pada skenario *early stopping* menunjukkan pembelajaran stabil. *Training* dan *validation accuracy* meningkat konsisten dari sekitar 0,25 hingga di atas 0,80, menandakan generalisasi baik tanpa *overfitting*. *Training* dan *validation loss* menurun stabil, dengan satu lonjakan validasi yang bersifat anomali. *Early stopping* bekerja efektif menjaga performa model selama proses pelatihan berlangsung secara keseluruhan. Informasi grafik *accuracy* dan *loss* pada skenario *early stopping* ditunjukkan pada Gambar 3.



Gambar 3. Grafik *Accuracy* dan *loss*


Grafik *accuracy* dan *loss Fold 3* pada skenario *epoch 50* menunjukkan *overfitting* berat. *Training accuracy* meningkat hingga di atas 0,90 dan *Training loss* turun tajam, namun *validation accuracy* berfluktuasi kuat dan *validation loss* sering melonjak. Tanpa *early stopping*, model terlalu menyesuaikan data latih dan berisiko menghasilkan generalisasi yang buruk pada data baru. Informasi grafik *accuracy* dan *loss* pada skenario *epoch 50* ditunjukkan pada Gambar 4.



Gambar 4. Grafik *Accuracy* dan *loss*

Confusion matrix *fold 4* skenario *early stopping* menunjukkan bahwa model VGG16 sangat baik mengenali kelas *diserang_hama* dan *bercak_hitam* dengan tingkat prediksi benar yang tinggi. Sebaliknya, kelas *bercak_putih* dan *sehat* masih sering mengalami kesalahan klasifikasi akibat kemiripan visual dan intensitas fitur yang rendah. Faktor noise citra


dan kemungkinan ketidakseimbangan data turut memengaruhi performa, sehingga diperlukan peningkatan kualitas data dan strategi pemrosesan untuk memperbaiki akurasi pada kedua kelas tersebut. Hasil *confusion matrix fold 4* skenario *early stopping* di tampilkan pada Gambar 5.



Gambar 5. *Confusion Matrix*

Confusion matrix *Fold 3* pada *epoch 50* menunjukkan akurasi sangat tinggi pada kelas *bercak_hitam* dan *diserang_hama*, namun hal ini cenderung dipengaruhi *overfitting*. Kelas *bercak_putih* dan *sehat* masih mengalami kesalahan klasifikasi akibat kemiripan visual. Hasil ini menegaskan bahwa peningkatan *epoch* tanpa *early stopping* tidak menjamin generalisasi yang lebih baik, meskipun akurasi beberapa kelas terlihat sangat tinggi.

Hasil *confusion matrix fold 3* skenario *epoch 50* di tampilkan pada Gambar 6.



Gambar 6. *Confusion Matrix*

4.2 Model Mobilenetv2

Berdasarkan hasil evaluasi skenario *early stopping*, *fold* ke-1 dan *fold* ke-2 sama-sama menghasilkan nilai akurasi dan *macro recall* tertinggi sebesar 0,96. Dengan demikian, kedua *fold* tersebut dapat dikategorikan sebagai *fold* dengan performa terbaik, dan *fold* ke-1 dipilih

sebagai *fold* representatif. Berikut *classification report macro avg* skenario *early stopping* ditampilkan pada Tabel 3.

Tabel 3. *Classification report Macro AVG*


Fold	Accuracy	Precision	Recall	F1-Score
1	0.96	0.96	0.96	0.96
2	0.96	0.96	0.96	0.96
3	0.96	0.89	0.87	0.87
4	0.95	0.95	0.95	0.95
5	0.95	0.95	0.95	0.95

Fold ke-4 skenario *epoch* 50 mencatat nilai akurasi dan *macro recall* tertinggi, masing-masing sebesar 0,94. Dengan demikian, kedua *fold* tersebut dikategorikan sebagai *fold* dengan performa terbaik, dan salah satunya dipilih secara representatif untuk analisis visual. Berikut *classification report macro avg* skenario *epoch* 50 ditampilkan pada Tabel 4.

Tabel 4. *Classification report Macro AVG*


Fold	Accuracy	Precision	Recall	F1-Score
1	0.94	0.94	0.94	0.94
2	0.93	0.94	0.93	0.93
3	0.92	0.92	0.92	0.91
4	0.94	0.94	0.94	0.94
5	0.90	0.91	0.90	0.90

Grafik *accuracy* dan *loss fold* 1 skenario *early stopping* MobileNetV2 menunjukkan peningkatan akurasi sangat cepat di awal hingga di atas 0,90, lalu memasuki fase stabil di kisaran 0,95–0,97. *Training* dan *validation loss* menurun tajam dan stabil tanpa indikasi *overfitting*. Namun, peningkatan setelah 10–15 *epoch* sangat marginal, sehingga *early stopping* penting untuk efisiensi dan mencegah pelatihan berlebih. Informasi grafik *accuracy* dan *loss* pada skenario *early stopping* ditunjukkan pada Gambar 7.




Gambar 7. Grafik *accuracy* dan *loss*

Grafik *accuracy* dan *loss fold* 1 skenario *epoch* 50 MobileNetV2 menunjukkan peningkatan akurasi sangat cepat dari sekitar 0,33 hingga di atas 0,85, lalu stabil di kisaran 0,95–0,97 sejak *epoch* 10–15. *Training* dan *validation loss* menurun tajam lalu melandai. Meski *overfitting* tidak terlihat, pelatihan hingga 50 *epoch* kurang efisien karena model telah konvergen lebih awal dan menambah biaya komputasi. Informasi grafik *accuracy* dan *loss* pada skenario *epoch* 50 ditunjukkan pada Gambar 8.




Gambar 8. Grafik *accuracy* dan *loss*

Confusion matrix *fold* 1 MobileNetV2 dengan *early stopping* menunjukkan performa sangat tinggi dan seimbang di seluruh kelas. Kelas bercak hitam dan diserang_hama dikenali hampir sempurna, sementara bercak putih dan sehat hanya mengalami sedikit kesalahan akibat kemiripan visual. Jumlah kesalahan yang minimal dan tidak terpusat pada satu kelas menunjukkan kemampuan generalisasi yang baik serta efektivitas *early stopping* dalam mencegah *overfitting* dan menjaga stabilitas performa model. Hasil *confusion matrix fold* 1 skenario *early stopping* di tampilkan pada Gambar 9.



Gambar 9. *Confusion Matrix*

Confusion matrix *fold* 1 MobileNetV2 pada skenario 50 *epoch* menunjukkan performa sangat tinggi pada kelas bercak_hitam dan diserang_hama dengan prediksi hampir sempurna. Kelas sehat juga terklasifikasi dengan baik, namun bercak_putih masih menjadi sumber kesalahan utama akibat tumpang tindih visual. Meskipun akurasi tinggi, peningkatan performa dibanding *epoch* lebih rendah relatif kecil, sehingga pelatihan hingga 50 *epoch* kurang efisien dan berpotensi menurunkan efektivitas generalisasi. Hasil *confusion matrix fold* 1 skenario *early stopping* di tampilkan pada Gambar 10.



Gambar 10. *Confusion Matrix*

4.3 Perbandingan Model

Perbandingan kinerja model dilakukan untuk menentukan arsitektur *Convolutional Neural Network* (CNN) dan skenario pelatihan terbaik dalam klasifikasi penyakit daun bakau *Ceriops tagal*. Evaluasi difokuskan pada metrik *accuracy* dan macro average recall, karena recall memiliki peran penting dalam sistem deteksi penyakit, khususnya untuk meminimalkan kesalahan identifikasi daun sakit sebagai daun sehat.

Hasil evaluasi menunjukkan bahwa MobileNetV2 secara konsisten menghasilkan nilai *accuracy* yang lebih tinggi dan stabil dibandingkan VGG16 pada seluruh skenario pelatihan. Pada skenario *early stopping*, MobileNetV2 mencapai *accuracy* tertinggi sebesar 0,96, yang diperoleh secara konsisten pada beberapa *fold*. Sebaliknya, VGG16 pada skenario yang sama hanya mencapai *accuracy* maksimum 0,79, dengan variasi performa antar *fold* yang cukup besar.

Pada skenario pelatihan 50 *epoch*, VGG16 sempat mencapai *accuracy* tertinggi sebesar 0,87 pada satu *fold* tertentu. Namun, nilai tersebut tidak konsisten karena *fold* lain menunjukkan penurunan performa yang signifikan hingga di bawah 0,40. Kondisi ini mengindikasikan bahwa peningkatan *epoch* pada VGG16 cenderung menyebabkan *overfitting*, sehingga nilai *accuracy* tinggi yang diperoleh tidak mencerminkan kemampuan generalisasi model secara keseluruhan.

Berbeda dengan VGG16, MobileNetV2 pada skenario 50 *epoch* tetap mempertahankan *accuracy* tinggi di kisaran 0,90–0,94 pada seluruh *fold*, meskipun tidak menunjukkan peningkatan yang signifikan dibandingkan skenario *early stopping*. Hal ini menunjukkan bahwa MobileNetV2 telah mencapai kondisi konvergen lebih awal dan tidak membutuhkan pelatihan dalam jumlah *epoch* yang besar.

Dari sisi macro average recall, MobileNetV2 kembali menunjukkan keunggulan yang jelas. Pada skenario *early stopping*, nilai recall mencapai 0,96, yang menandakan bahwa model mampu mengenali seluruh kelas penyakit daun bakau secara seimbang. Tingginya nilai recall ini sangat penting dalam konteks klasifikasi penyakit tanaman, karena kesalahan deteksi penyakit dapat berdampak langsung pada kegagalan upaya penanganan dini.

Sebaliknya, VGG16 menunjukkan nilai recall yang fluktuatif. Pada skenario *early stopping*, recall tertinggi hanya mencapai 0,79, sementara pada beberapa *fold* lain nilainya turun drastis hingga 0,31. Pada skenario 50 *epoch*, meskipun terdapat satu *fold* dengan recall tinggi (0,87), nilai recall pada *fold* lainnya sangat rendah. Kondisi ini menunjukkan bahwa VGG16 memiliki kecenderungan tidak stabil dalam mengenali seluruh kelas, khususnya pada dataset dengan jumlah terbatas dan tingkat kemiripan visual antar kelas yang tinggi.

Secara keseluruhan, hasil perbandingan menunjukkan bahwa MobileNetV2 dengan skenario *early stopping* merupakan kombinasi terbaik, karena mampu menghasilkan nilai *accuracy* dan macro recall tertinggi sebesar 0,96 serta menunjukkan performa yang stabil pada seluruh *fold* pengujian. Sementara itu, VGG16 memang dapat mencapai *accuracy* tinggi pada kondisi tertentu, namun performanya tidak konsisten dan sangat bergantung pada pembagian data, sehingga

kurang andal untuk penggunaan praktis pada data baru. Dari perspektif deteksi penyakit, nilai recall yang tinggi dan stabil pada MobileNetV2 menjadikannya lebih aman dan efektif dalam mengenali seluruh kelas penyakit daun bakau dibandingkan VGG16. Selain itu, pelatihan hingga 50 *epoch* tidak memberikan peningkatan performa yang signifikan pada MobileNetV2, bahkan cenderung tidak efisien, sedangkan pada VGG16 justru meningkatkan risiko terjadinya *overfitting*, yang berdampak negatif terhadap kemampuan generalisasi model.

5. KESIMPULAN

- a. Hasil perbandingan menunjukkan bahwa MobileNetV2 dengan skenario *early stopping* merupakan model terbaik, dengan nilai *accuracy* dan macro average recall tertinggi sebesar 0,96, serta performa yang stabil pada seluruh *fold* pengujian. Hal ini menunjukkan MobileNetV2 memiliki kemampuan generalisasi yang sangat baik pada dataset penelitian.
- b. Model VGG16 mampu mencapai *accuracy* tinggi pada kondisi tertentu, khususnya pada pelatihan 50 *epoch*, namun performanya tidak konsisten antar *fold* dan menunjukkan kecenderungan *overfitting*, sehingga kurang andal untuk diterapkan pada data baru atau penggunaan praktis.
- c. Untuk pengembangan yang selanjutnya, penelitian dapat ditingkatkan dengan penambahan jumlah dan variasi dataset, penerapan teknik balancing data, eksplorasi arsitektur CNN lain atau *ensemble* model, serta pengujian pada data lapangan secara real-time guna mendukung pengembangan sistem deteksi dini penyakit daun bakau yang lebih andal dan aplikatif.

UCAPAN TERIMA KASIH

Penulis menyampaikan rasa syukur kepada Tuhan Yang Maha Esa atas segala kekuatan dan pemahaman ilmu yang telah dianugerahkan, serta mengucapkan terima kasih kepada orang tua dan seluruh pihak yang telah berperan memberikan dukungan dalam pelaksanaan dan penyelesaian penelitian ini.

DAFTAR PUSTAKA

- [1] L. Qadrini, "Penyuluhan Manfaat Bakau kepada Masyarakat Pesisir Desa Panyampa," *J. Abdi Masy. Indones.*, vol. 2, no. 2, pp. 719–726, 2022, doi: 10.54082/jamsi.316.
- [2] M. D. Spalding *et al.*, "The State of Mangroves World's Mangroves 2021," 2021, [Online]. Available: www.mangrovealliance.org and www.globalmangrovewatch.org contact: contact@mangrovealliance.org membership: membership@mangrovealliance.org
- [3] R. O. Pamungkas, N. Rachmawati, and Susilawati, "Identifikasi Kesehatan Tanaman Bakau Laki (*Rhizophora mucronata* Lamk) Di Desa Betung Kecamatan Kusan Hilir Kabupaten Tanah Bumbu Kalimantan Selatan," *J. Sylva Sci.*, vol. 02, no. 6, pp. 1123–1132, 2019.
- [4] A. P. Maulida, E. Agustina, P. P. Aceh, and T. Mangrove, "(1), 2) 1)," no. 2013, pp. 226–233, 2019.
- [5] A. A. Aznawi, M. Basyuni, D. S. Hanafiah, S. H. Larekeng, and S. P. Mulya Sari, "Impact of Pest and Diseases on Mangrove Forest Rehabilitation in Indonesia: A Review," *Online J. Biol. Sci.*, vol. 24, no. 4, pp. 728–738, 2024, doi: 10.3844/ojbsci.2024.728.738.
- [6] M. I. Fathur Rozi, N. O. Adiwijaya, and D. I. Swasono, "Identifikasi Kinerja Arsitektur Transfer Learning Vgg16, Resnet-50, Dan Inception-V3 Dalam Pengklasifikasian Citra Penyakit Daun Tomat," *J. Ris. Rekayasa Elektro*, vol. 5, no. 2, p. 145, 2023, doi: 10.30595/jrre.v5i2.18050.
- [7] F. Zaelani and Y. Miftahuddin, "Perbandingan Metode EfficientNetB3 dan MobileNetV2 Untuk Identifikasi Jenis Buah-buahan Menggunakan Fitur Daun," *J. Ilm. Teknol. Infomasi Terap.*, vol. 9, no. 1, pp. 1–11, 2022, doi: 10.33197/jitter.vol9.iss1.2022.911.
- [8] A. S. Mashuri and A. Sunyoto, "Klasifikasi Penyakit Pada Daun Cabai Menggunakan Arsitektur VGG16," vol. 6, no. 2, pp. 296–304, 2024, doi: 10.33650/jeeecom.v4i2.
- [9] B. H. Nurhadi, "Tiruan Dan Deep learning Dalam Diagnosa Demam Berdarah Dan Tifus," vol. 16, no. 2, 2024.
- [10] N. Wayan, Y. Wiani, I. M. A. Wirawan, K. Yota, and E. Aryanto, "Klasifikasi Gerakan Tangan Berbasis Sinyal sEMG," *JEPIN (Jurnal Edukasi dan Penelit. Inform.)*, vol. 11, no. 1, pp. 121–128, 2025.
- [11] N. Putu Dita Ariani Sukma Dewi, M. Windu Antara Kesiman, I. Made Gede Sunarya, I. Gusti Ayu Agung Diatri Indradewi, and I. Gede Andika, "Classification of Herbal Plant Leaf Types Based on Lontar Usada Taru

- Pramana Using CNN,” *Februari*, vol. 23, no. 1, pp. 271–283, 2024.
- [12] P. A. Nugroho, I. Fenriana, and R. Arijanto, “Implementasi *Deep learning* Menggunakan *Convolutional Neural Network* (CNN) Pada Ekspresi Manusia,” *Algor*, vol. 2, no. 1, pp. 12–21, 2020.
- [13] G. S. Anom Mahartha, Aris Gunadi, “Analisis Hyperparameter Pada Klasifikasi Jenis Daging Menggunakan Algoritma *Convolutional Neural Network*,” *J. Sains Komput. Inform. (J-SAKTI)*, vol. 8, no. 1, pp. 25–34, 2024.
- [14] D. Ayu Pusparani, M. Windu Antara Kesiman, and K. Yota Ernanda Aryanto, “Identification of Little Tuna Species Using *Convolutional Neural Networks* (CNN) Method and ResNet-50 Architecture,” *Indones. J. Artif. Intell. Data Min.*, vol. 8, no. 1, pp. 86–93, 2025.
- [15] P. H. Setadewa *et al.*, “Segmentasi Bangunan Perkotaan Pada Citra Satelit Beresolusi Tinggi: Cnn , U-Net (Vgg16), Dan Deeplabv3 +,” vol. 4, no. 4, pp. 337–347, 2025.
- [16] G. A. Pratama *et al.*, “*Convolutional Neural Network* Dan Faster Region *Convolutional Neural Network*,” vol. 12, no. 3, pp. 2776–2785, 2024.
- [17] S. Darmawan Putra Bahari and U. Latifa, “Klasifikasi Buah Segar Menggunakan Teknik *Computer Vision* Untuk Pendeteksian Kualitas Dan Kesegaran Buah,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 3, pp. 1567–1573, 2023, doi: 10.36040/jati.v7i3.6871.
- [18] I. P. A. Suputra, I. G. A. Gunadi, and I. M. G. Sunarya, “Hyperparameter Optimization with *MobileNet* Architecture and *VGG* Architecture for Urban Traffic Density Classification Using Bali Camera Image Data,” *Sinkron*, vol. 9, no. 3, pp. 1132–1145, 2025, doi: 10.33395/sinkron.v9i3.14971.
- [19] M. W. A. Kesiman, I. M. G. Sunarya, and I. G. L. T. Sumantara, “Comparative Analysis of CNN Methods for Periapical Radiograph Classification,” *J. Nas. Pendidik. Tek. Inform.*, vol. 13, no. 2, pp. 204–214, 2024, doi: 10.23887/janapati.v13i2.71664.
- [20] A. S. Ardiansyah and A. Nugroho, “Klasifikasi Penyakit Daun Kopi Dengan Arsitektur *MobileNetV2*,” *J. Ilmu Komput. dan Bisnis*, vol. 14, no. 1, pp. 66–73, 2023, doi: 10.47927/jikb.v14i1.622.
- [21] K. A. Tazkira Turahman, Erfan Hasmin, “Analisis Perbandingan Metode *Convolutional Neural Network* (CNN) dan *MobileNet* dalam Klasifikasi Penyakit Daun Padi,” vol. 9, no. March, pp. 368–377, 2025.