

KLASIFIKASI PENYAKIT TANAMAN DAUN PADI MENGGUNAKAN METODE DEEP LEARNING DENGAN TEKNIK TRANSFER LEARNING MOBILENET

Hadie Pratama Tulili¹, Anindita Septiarini², Hamdani³

^{1,2,3}Program Studi Informatika, Universitas Mulawarman

Jl. Kuaro, Gn. Kelua, Samarinda, 75119

¹hadiepratamatulili@gmail.com, ²anindita@unmul.ac.id, ³hamdani@unmul.ac.id

Abstract

Rice farming plays an important role in food security, but production is often disrupted by leaf diseases such as Blast, Brown spot, and Hispa. Manual classification is less effective as it requires time and specific expertise. This study proposes automatic classification using transfer learning with MobileNetV1 and MobileNetV2 architectures. The original contribution of this research lies in the validation of performance and specific optimization of MobileNet architectures for rice leaf disease cases, including a comparative analysis of Dense layer configurations and training data ratios. The dataset consists of 2000 images divided into four classes, split into training, testing, and validation sets to prevent overfitting. The models were trained using Dense layer configurations of 32, 64, and 256 neurons with data split ratios of 7:2:1 and 8:1:1. The best model was achieved by MobileNetV2 with 64 neurons and an 8:1:1 ratio, resulting in 93.50% accuracy. These results show that MobileNetV2 is an efficient and accurate method for classifying rice leaf diseases and can support farmers in making faster and more precise decisions in crop management.

Keywords : Rice leaf diseases, image classification, deep learning, transfer learning, MobileNet

Abstrak

Pertanian padi memiliki peran penting dalam ketahanan pangan, namun produksi sering terganggu akibat penyakit daun seperti Blast, Brown spot, dan Hispa. Klasifikasi manual kurang efektif karena membutuhkan waktu dan keahlian khusus. Penelitian ini mengusulkan klasifikasi otomatis menggunakan transfer learning dengan arsitektur MobileNetV1 dan MobileNetV2. Kontribusi orisinal dari penelitian ini berupa validasi performa dan optimasi spesifik pada arsitektur MobileNet untuk kasus penyakit daun padi, termasuk analisis komparatif pada konfigurasi *Dense layer* dan rasio data *training*. Dataset terdiri dari 2000 citra empat kelas yang dibagi menjadi data train, test, dan validation untuk mencegah overfitting. Model dilatih menggunakan konfigurasi *Dense layer* 32, 64, dan 256 dengan rasio data 7:2:1 dan 8:1:1. Model terbaik diperoleh dari MobileNetV2 dengan 64 *neuron* dan rasio 8:1:1, menghasilkan akurasi 93,50%. Hasil ini menunjukkan bahwa MobileNetV2 dapat menjadi metode yang efisien dan akurat untuk klasifikasi penyakit daun padi serta mendukung pengambilan keputusan petani secara lebih cepat.

Kata kunci : Penyakit daun padi, klasifikasi citra, deep learning, transfer learning, MobileNet

1. PENDAHULUAN

Pertanian adalah kegiatan yang melibatkan penanaman, perawatan, dan panen tanaman untuk menghasilkan makanan dan bahan baku bagi manusia [1]. Pertanian padi, khususnya, memainkan peran penting dalam penyediaan

pangan global karena menjadi salah satu sumber utama karbohidrat serta memiliki nilai ekonomi yang signifikan bagi petani dan masyarakat [2]. Keberhasilan pertanian sangat dipengaruhi oleh berbagai faktor seperti kondisi iklim, kesuburan tanah, dan praktik pengelolaan yang tepat [3]. Padi (*Oryza sativa*) merupakan salah satu

tanaman pangan utama yang berperan vital dalam ketahanan pangan di berbagai negara, khususnya Indonesia [4]. Sebagai makanan pokok bagi sebagian besar penduduk dunia [5], produksi padi yang optimal sangat diperlukan.

Namun, pertanian padi sering menghadapi tantangan, salah satunya adalah serangan penyakit yang dapat menurunkan hasil panen [6]. Daun padi sebagai bagian penting dalam proses fotosintesis sangat rentan terhadap infeksi penyakit, yang dapat berdampak langsung pada pertumbuhan dan produktivitas tanaman. Penyakit seperti *Blast*, *Brown spot*, dan *Hispa* sering menyerang daun padi dan menyebabkan kerusakan signifikan jika tidak ditangani dengan baik. Oleh karena itu, upaya penanganan penyakit daun padi menjadi langkah krusial dalam menjaga hasil panen serta keberlanjutan sektor pertanian.

Klasifikasi penyakit pada tanaman daun padi secara manual memerlukan keahlian khusus dan sering kali menjadi tantangan bagi petani yang memiliki keterbatasan dalam pengetahuan teknis atau sumber daya. Kesulitan dalam mengenali gejala penyakit pada daun padi dapat menyebabkan keterlambatan dalam pengambilan tindakan, yang berpotensi menurunkan hasil panen. Untuk mengatasi masalah ini, teknologi kecerdasan buatan (*Artificial Intelligence*) dan pembelajaran mesin (*Machine Learning*) dapat diterapkan di sektor pertanian. Salah satu pendekatan yang banyak digunakan adalah *transfer learning*, yang memungkinkan model yang telah dilatih sebelumnya untuk diterapkan pada tugas klasifikasi penyakit tanaman daun padi secara otomatis [7]. Dengan teknologi ini, petani dapat memperoleh informasi lebih cepat dan akurat mengenai kondisi tanaman mereka, sehingga langkah pencegahan atau pengobatan dapat dilakukan dengan lebih efektif.

Transfer learning merupakan teknik dalam pembelajaran mesin yang memanfaatkan model yang telah dilatih pada dataset berskala besar untuk menyelesaikan tugas yang lebih spesifik dengan jumlah data terbatas [8]. Teknik ini telah diterapkan dalam berbagai model arsitektur, seperti Residual Network (ResNet) dan Visual Geometry Group (VGG), yang mampu meningkatkan akurasi klasifikasi citra secara signifikan [9]. Salah satu arsitektur populer untuk *transfer learning* adalah MobileNet, yang dirancang untuk efisiensi komputasi pada perangkat dengan keterbatasan sumber daya. MobileNet menggunakan teknik *depthwise separable convolution*, yang mengurangi jumlah parameter dan operasi komputasi tanpa mengorbankan akurasi model [10].

MobileNet menjadi solusi yang efisien karena mampu mengolah citra daun padi dengan cepat dan tetap mempertahankan akurasi tinggi. Arsitektur ini dapat digunakan dalam berbagai lingkungan komputasi, baik pada perangkat dengan sumber daya terbatas maupun sistem berbasis server yang memproses data dalam skala besar. Dengan keunggulan dalam efisiensi dan akurasi, MobileNet dapat diterapkan untuk menganalisis gejala penyakit tanaman daun padi secara otomatis, sehingga mendukung sistem pertanian cerdas dalam membantu petani mengambil keputusan yang lebih cepat dan tepat dalam pengelolaan tanaman.

Beberapa penelitian sebelumnya telah menerapkan *transfer learning* dengan berbagai arsitektur model dalam klasifikasi penyakit tanaman. Misalnya, penggunaan arsitektur seperti ResNet dan Inception dalam deteksi penyakit tanaman gandum menunjukkan hasil yang menjanjikan dalam pengenalan gambar dengan akurasi sebesar 98% [11]. Penelitian dengan menggunakan arsitektur Neural Search Architecture Mobile (NasNet Mobile) dan MobileNet pada klasifikasi penyakit tanaman daun kentang juga memberikan hasil yang baik dengan akurasi 90,86% untuk NasNet Mobile dan 81,60% untuk MobileNet [12]. Meskipun hasil tersebut cukup menjanjikan, penelitian terdahulu masih memiliki keterbatasan, di antaranya adalah kurangnya eksplorasi perbandingan antarversi arsitektur MobileNet, serta belum adanya fokus pada penyakit daun padi yang spesifik seperti *Blast*, *Brown spot*, dan *Hispa*.

Berdasarkan celah penelitian tersebut, penelitian ini mengusulkan pendekatan klasifikasi otomatis menggunakan arsitektur MobileNetV1 dan MobileNetV2. Keunggulan MobileNet dibandingkan arsitektur lain terletak pada efisiensi komputasi dan kebutuhan parameter yang lebih ringan, sehingga memungkinkan penerapan langsung pada perangkat dengan sumber daya terbatas. Penelitian ini bertujuan untuk membandingkan performa kedua arsitektur tersebut dalam klasifikasi penyakit daun padi, sehingga dapat diketahui model mana yang lebih efektif dalam memberikan prediksi akurat serta mendukung sistem pertanian cerdas. Dengan demikian, hasil penelitian diharapkan dapat memberikan kontribusi nyata dalam pengembangan teknologi klasifikasi penyakit tanaman padi yang efisien, akurat, dan aplikatif.

2. METODOLOGI PENELITIAN


Penelitian ini menggunakan metode klasifikasi citra untuk mengklasifikasikan

penyakit daun padi berbasis *transfer learning* dengan memanfaatkan arsitektur MobileNet. MobileNet merupakan arsitektur *Convolutional Neural Network* (CNN) yang dirancang secara khusus agar efisien dan ringan digunakan pada perangkat dengan keterbatasan komputasi [13]. Arsitektur ini menggunakan teknik *depthwise separable convolution* untuk menurunkan jumlah parameter dan operasi komputasi dibandingkan konvolusi standar, sehingga lebih optimal untuk diterapkan dalam klasifikasi gambar pada perangkat *mobile* atau sistem komputasi terbatas.

MobileNet memiliki dua varian utama yang digunakan dalam penelitian ini, yaitu:

1. MobileNetV1

MobileNetV1 adalah versi pertama dari arsitektur MobileNet yang mengimplementasikan secara penuh teknik *depthwise separable convolution*. Setiap gambar diproses melalui serangkaian lapisan konvolusi yang dipisahkan menjadi dua tahap, yaitu *depthwise convolution* untuk mengekstraksi fitur spasial dan *pointwise convolution* untuk menggabungkan informasi antar saluran (*channel*). Pendekatan ini memungkinkan proses ekstraksi fitur dilakukan dengan komputasi yang jauh lebih efisien dibandingkan konvolusi biasa. MobileNetV1 mempertahankan struktur dasar CNN, namun dengan jumlah parameter dan ukuran model yang lebih kecil, sehingga cocok untuk implementasi di perangkat *mobile* atau sistem dengan keterbatasan sumber daya. Dengan karakteristik tersebut, MobileNetV1 menjadi pilihan yang ideal untuk tugas-tugas klasifikasi citra pada lingkungan dengan keterbatasan memori dan kecepatan pemrosesan.




Gambar 1. Struktur Model MobileNetV1

2. MobileNetV2

MobileNetV2 merupakan pengembangan dari versi sebelumnya, dengan memperkenalkan *inverted residual block* dan *linear bottleneck* sebagai inovasi utama. Struktur *inverted residual block* memungkinkan representasi fitur yang lebih efektif melalui ekspansi dan reduksi dimensi saluran (*channel*) di dalam blok jaringan.


MobileNetV2 tetap menggunakan teknik *depthwise separable convolution*, namun dengan efisiensi dan akurasi yang lebih baik dibandingkan MobileNetV1.



Gambar 2. Struktur Model MobileNetV2

2.1. Skema Alur Penelitian

Metode penelitian ini dilakukan melalui beberapa tahapan yang saling berkesinambungan, dimulai dari pengumpulan data hingga evaluasi model, yang keseluruhan alurnya dapat dilihat pada Gambar 3.



Gambar 3. Tahapan Pelaksanaan Penelitian

Pada Gambar 3, dijelaskan tahapan dalam penelitian ini yaitu:

1. Pengumpulan Data

Data citra daun padi diambil dari sumber dataset publik (Kaggle). Dataset ini berisi empat kelas yaitu Blast, Brown Spot, Hispa, dan Healthy.

2. Perancangan Data

Tahap ini meliputi penghapusan sebagian citra agar jumlah data antar kelas seimbang,

pembagian data ke dalam training, validation, dan testing set, serta penerapan preprocessing dan augmentasi untuk memperluas variasi data.

3. Implementasi Model

Data hasil perancangan kemudian digunakan untuk membangun model klasifikasi dengan arsitektur MobileNetV1 dan MobileNetV2 menggunakan metode transfer learning.

4. Evaluasi Model

Model yang telah dilatih diuji dengan data testing untuk memperoleh metrik evaluasi seperti akurasi, precision, recall, F1-score, dan confusion matrix sebagai tolok ukur performa klasifikasi.

2.2. Pengumpulan Data

Penelitian ini menggunakan data citra yang didapatkan dari dataset publik yaitu Kaggle yang berjudul "Rice Leafs Diseases Detection". Jumlah data citra yang akan digunakan pada penelitian adalah 2000 citra yang terdiri empat kelas, yaitu *Blast*, *Brown spot*, *Hispa*, dan *Healthy* dengan masing-masing kelas berjumlah 500 data citra. Citra yang digunakan dalam penelitian memiliki spesifikasi yang seragam untuk memastikan kualitas gambar yang optimal. Rincian informasi mengenai citra dalam data yang dikumpulkan dapat dilihat pada Tabel 1.

TABEL 1. RINCIAN INFORMASI DATA CITRA

No	Spesifikasi	Rentang/Nilai Tunggal
1	Format	JPG
2	Ukuran File	149 – 7.374 kb
3	Resolusi	1.600 x 1.600 – 4.000 x 3.000 piksel
4	Jarak Objek	15 – 25 cm
5	Total Citra	2000 citra

2.3. Perancangan Data

Perancangan data merupakan tahap awal dalam pengolahan dataset yang bertujuan untuk menyiapkan data agar siap digunakan dalam proses pelatihan dan pengujian model klasifikasi. Untuk memastikan distribusi data yang seimbang, dilakukan proses penyamaan jumlah citra pada setiap kelas. Citra dari kelas dengan jumlah terbanyak akan dikurangi sehingga seluruh kelas memiliki jumlah data yang sama dengan kelas dengan jumlah data terkecil. Hal ini bertujuan untuk mencegah bias klasifikasi akibat distribusi data yang tidak merata.

Setelah proses penyamaan jumlah citra, total sebanyak 2000 citra digunakan dan dibagi menjadi tiga subset, yaitu *data training*, *data*

testing, dan *data validation*. Proses pembagian dataset dilakukan secara otomatis menggunakan pustaka *splitfolders* dengan dua skema rasio pembagian, yaitu rasio 7:2:1 dan 8:1:1. Pada rasio 7:2:1, dataset dibagi menjadi 350 citra untuk *data training*, 100 citra untuk *data testing*, dan 50 citra untuk *data validation*. Sedangkan pada rasio 8:1:1, data terbagi menjadi 400 citra untuk *data training*, 50 citra untuk *data testing*, dan 50 citra untuk *data validation*. Pembagian dataset dengan metode ini merupakan pendekatan umum dalam penelitian berbasis *deep learning*, terutama pada dataset yang memiliki jumlah data antara 100 hingga 1.000.000 [14].

Setelah proses pembagian, seluruh data yang terdapat dalam folder hasil split dimuat ke dalam tahap *preprocessing* dan augmentasi menggunakan fungsi *ImageDataGenerator* dari pustaka TensorFlow. Proses ini bertujuan untuk meningkatkan kualitas dan keragaman data sebelum dimasukkan ke dalam model pelatihan. Tahapan *preprocessing* dan augmentasi yang dilakukan meliputi:

1. Resize

Seluruh citra diubah ukurannya menjadi 224 × 224 piksel. Ukuran ini dipilih agar sesuai dengan format input standar arsitektur MobileNet yang telah dilatih sebelumnya pada dataset ImageNet [15]. Penggunaan ukuran input yang seragam membantu memaksimalkan proses *transfer learning* [16].

2. Normalisasi

Proses normalisasi dilakukan menggunakan fungsi *preprocess_input* dari MobileNet. Fungsi ini menyesuaikan nilai piksel gambar ke dalam rentang [-1, 1] dengan cara membagi setiap nilai piksel dengan 127.5 kemudian dikurangi 1. Langkah ini dilakukan untuk menyamakan skema normalisasi data dengan model pra-latih (*pre-trained model*) MobileNet.

3. Rotate

Augmentasi rotasi dilakukan dengan memutar citra asli hingga sudut maksimum 30°. Proses ini menghasilkan variasi citra yang berbeda tanpa mengubah kelas citra, sehingga model menjadi lebih adaptif terhadap variasi posisi daun dalam gambar.


4. Flip

Teknik flip digunakan untuk membalik citra secara *horizontal* dan *vertikal*. *Flip horizontal* menghasilkan gambar pantulan dari sisi kiri ke kanan, sedangkan *flip vertikal* membalik gambar dari atas ke bawah. Dengan variasi *flip*, model

dapat belajar mengenali objek citra dengan orientasi yang berbeda.

2.4. Implementasi Model

Dalam penelitian ini, dataset citra daun padi yang telah melalui tahapan *preprocessing* dan augmentasi digunakan dalam proses pemodelan klasifikasi menggunakan dua arsitektur MobileNet yang berbeda, yaitu MobileNetV1 dan MobileNetV2. Rancangan struktur model MobileNet yang digunakan dapat dilihat pada Gambar 4.



Gambar 4. Rancangan Struktur Model MobileNet

Penjelasan mengenai masing-masing bagian dari struktur model diatas adalah sebagai berikut:

1. Base Model

Model dasar yang digunakan adalah MobileNetV1 dan MobileNetV2 yang dimuat menggunakan bobot pra-pelatihan dari dataset ImageNet (*pretrained weights*). Pada saat pemanggilan model, *input shape* yang dipakai berukuran 224x224 piksel dengan mode RGB agar sesuai dengan ukuran *input* dari MobileNet. Setelah itu bagian *fully connected layer* bawaan di bagian akhir (*top layers*) dihapus dengan mengatur parameter *include_top=False*. Hal ini bertujuan agar model dapat disesuaikan dengan jumlah kelas pada dataset yang digunakan dalam penelitian ini, yaitu empat kelas. Kemudian pada tahap awal, parameter dari *base model* tidak dilatih ulang (*trainable=False*), sehingga model hanya berfungsi sebagai ekstraktor fitur (*feature extractor*).

2. Global Average Pooling 2D

Lapisan ini berfungsi untuk mereduksi dimensi output dari feature map menjadi satu vektor dengan cara menghitung rata-rata nilai dari setiap feature map. Dengan demikian, Global Average Pooling 2D menggantikan penggunaan fully connected layer tradisional pada tahap akhir jaringan, sehingga dapat mengurangi risiko overfitting dan jumlah parameter yang perlu dipelajari.

3. Dense Layer

Merupakan fully connected layer yang terdiri dari sejumlah *neuron* dengan fungsi aktivasi ReLU. Dalam penelitian ini, dilakukan beberapa percobaan dengan jumlah *neuron* yang berbeda, yaitu 32, 64, dan 256 unit, untuk mengevaluasi pengaruh kompleksitas jaringan terhadap performa model.

4. Batch Normalization

Digunakan setelah layer *Dense* untuk menormalkan nilai output antar batch, menjaga distribusi data tetap stabil selama pelatihan. Teknik ini mempercepat proses konvergensi, membantu kestabilan pelatihan, dan mengurangi risiko overfitting.

5. Dropout

Digunakan untuk mengurangi risiko *overfitting* dengan menghilangkan beberapa *neuron* secara acak selama pelatihan. Dalam penelitian ini, dropout rate yang digunakan adalah 0,5.

6. Dense Layer (Output Layer)

Sebagai lapisan klasifikasi akhir yang terdiri dari 4 unit *neuron* dengan fungsi aktivasi softmax. Lapisan ini bertugas menghasilkan probabilitas prediksi dari masing-masing kelas (*Blast*, *Brown spot*, *Hispa*, dan *Healthy*).

Setelah arsitektur model selesai dibentuk, langkah selanjutnya adalah melakukan proses kompilasi model. Pada tahap ini, digunakan beberapa parameter sebagai berikut:

1. Loss Function

Loss Function yang digunakan yaitu *categorical_crossentropy*, karena perhitungan yang dilakukan adalah klasifikasi dengan lebih dari dua kelas (*multiclass classification*).

2. Optimizer

Optimizer yang digunakan adalah Adam, yang dikenal efisien dalam proses pembelajaran adaptif

dan konvergen lebih cepat dibandingkan algoritma optimasi lainnya.

3. Evaluation Metric

Metrik evaluasi yang digunakan adalah *accuracy*, yang berfungsi untuk mengukur seberapa baik model dalam mengklasifikasikan data dengan benar.

Beberapa parameter penting dalam proses pelatihan yang digunakan dalam penelitian ini adalah sebagai berikut:

1. Epoch

Jumlah epoch sebanyak 20 menunjukkan berapa kali seluruh dataset dilalui dalam proses pelatihan. Jumlah ini dipilih berdasarkan eksperimen awal agar model cukup belajar tanpa mengalami *overfitting*.

2. Batch size

Jumlah data yang diproses dalam satu iterasi pelatihan. Ukuran *batch size* yaitu 32 dipilih untuk menjaga keseimbangan antara efisiensi pelatihan dan kestabilan pembaruan bobot.

Beberapa *callback* dari Keras digunakan guna mengoptimalkan proses pelatihan, yaitu:

1. Costum Callback

Callback khusus yang dibuat untuk menghentikan pelatihan secara manual ketika model telah mencapai akurasi pelatihan lebih dari 97% dan akurasi validasi lebih dari 95%.

2. Early Stopping

Menghentikan pelatihan jika tidak terjadi peningkatan pada metrik validasi setelah beberapa epoch berturut-turut. Hal ini bertujuan untuk menghindari *overfitting*.

Selama proses pelatihan, model melakukan iterasi terhadap data training dan menghitung akurasi serta nilai *loss* pada data validasi setiap *epoch*.

2.5. Evaluasi Model

Confusion matrix adalah metode evaluasi yang digunakan untuk mengukur kinerja model klasifikasi dalam bidang pembelajaran mesin dan kecerdasan buatan. Matriks ini memberikan representasi visual dari hasil prediksi model dibandingkan dengan label sebenarnya, memungkinkan analisis rinci terhadap kesalahan

dan keberhasilan prediksi [17]. Perancangan pengujian pada penelitian ini menggunakan metode evaluasi confusion matrix dengan empat parameter, yaitu:

1. *True Positive* (TP): jumlah prediksi benar untuk kelas positif.
2. *True Negative* (TN): jumlah prediksi benar untuk kelas negatif.
3. *False Positive* (FP): jumlah prediksi salah di mana kelas negatif diklasifikasikan sebagai positif.
4. *False Negative* (FN): jumlah prediksi salah di mana kelas positif diklasifikasikan sebagai negatif.

Dari *Confusion matrix*, beberapa metrik evaluasi utama dapat dihitung, yaitu:

1. Accuracy

Accuracy adalah metrik yang menghitung proporsi prediksi benar terhadap total jumlah data. Metrik ini menunjukkan seberapa sering model menghasilkan prediksi yang benar. Namun, pada dataset dengan distribusi kelas tidak seimbang, akurasi saja tidak cukup untuk menggambarkan kinerja model secara menyeluruh. Perhitungan akurasi dapat dilihat pada Persamaan 1.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

2. Precision

Precision adalah rasio prediksi positif yang benar-benar positif. Metrik ini mengukur kemampuan model dalam meminimalisasi kesalahan prediksi positif (*False Positive*), sehingga menunjukkan keakuratan prediksi untuk kelas tertentu. Perhitungan precision dapat dilihat pada Persamaan 2.

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

3. Recall

Recall, atau sensitivitas, mengukur proporsi kasus positif yang berhasil diidentifikasi dengan benar oleh model. Metrik ini penting untuk memahami seberapa baik model dalam menemukan seluruh *instance* dari kelas positif yang ada dalam data. Perhitungan *recall* dapat dilihat pada Persamaan 3.

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

4. *F1-Score*

F1-Score adalah rata-rata harmonis dari *precision* dan *recall*. Metrik ini digunakan untuk menyeimbangkan kedua aspek tersebut, terutama pada kasus di mana distribusi data antar kelas tidak seimbang. *F1-Score* memberikan gambaran kinerja model secara lebih adil dengan mempertimbangkan kesalahan prediksi dan keberhasilan deteksi kelas positif. Perhitungan *F1-Score* dapat dilihat pada Persamaan 4.

$$F1\ Score = 2 \cdot \frac{Presicion \cdot Recall}{Precision + Recall} \quad (4)$$

Ilustrasi *confusion matrix* dari klasifikasi dapat dilihat pada Tabel 2.

TABEL II. *CONFUSION MATRIX* KLASIFIKASI PENYAKIT TANAMAN DAUN PADI

		Predicted Number			
		Blast	Brown spot	Hispa	Healthy
Actual Number	Blast	X ₁₁	X ₁₂	X ₁₃	X ₁₄
	Brown spot	X ₂₁	X ₂₂	X ₃₂	X ₄₂
	Hispa	X ₃₁	X ₃₂	X ₃₃	X ₃₄
	Healthy	X ₄₁	X ₄₂	X ₄₃	X ₄₄

3. HASIL DAN PEMBAHASAN

Berdasarkan hasil pengujian yang dilakukan terhadap dua arsitektur model yaitu MobileNetV1 dan MobileNetV2, diperoleh bahwa keduanya mampu melakukan klasifikasi citra daun padi dengan cukup baik. Evaluasi dilakukan dengan menggunakan data validasi yang telah dipisahkan pada saat pembagian dataset. Hasil akurasi validasi dari pengujian model dapat dilihat pada Tabel 3.

TABEL III. HASIL AKURASI VALIDASI PENGUJIAN MODEL

Model	Rasio Data	Neuron	Akurasi Validasi	Loss Validasi
Mobile NetV1	7:2:1	32	0,9250	0,2250
		64	0,9200	0,2163
		256	0,9200	0,1974
	8:1:1	32	0,9000	0,3521
		64	0,9050	0,3131
		256	0,9050	0,3379
Mobile NetV2	7:2:1	32	0,8650	0,3448
		64	0,8949	0,3277
		256	0,8850	0,3073
	8:1:1	32	0,8849	0,2751
		64	0,9100	0,2757
		256	0,9050	0,3159


Pada Tabel 4 dapat dilihat bahwa hasil akurasi validasi terbaik untuk model MobileNetV1 dengan rasio 7:2:1 diperoleh pada jumlah *neuron* 32, yaitu sebesar 0,9250 atau 92,5%, diikuti oleh *neuron* 64 dan 256 yang sama-sama memberikan akurasi 0,9200 atau 92%. Untuk rasio 8:1:1, akurasi validasi tertinggi dicapai oleh jumlah *neuron* 64 sebesar 0,9050 atau 90,5%, yang juga diikuti oleh nilai serupa pada *neuron* 256.

Sementara itu, pada model MobileNetV2 dengan rasio 7:2:1, konfigurasi *neuron* 64 memberikan akurasi validasi tertinggi sebesar 0,8949 atau 89,49%, lebih baik dibandingkan *neuron* 32 dan 256. Adapun pada rasio 8:1:1, konfigurasi *neuron* 64 juga menghasilkan akurasi validasi tertinggi yaitu 0,9100 atau 91%, menunjukkan bahwa jumlah *neuron* ini merupakan konfigurasi paling optimal untuk arsitektur MobileNetV2.

Selain akurasi validasi, analisis nilai *loss* validasi juga memperlihatkan kecenderungan yang sama, di mana model dengan akurasi tinggi cenderung memiliki nilai *loss* lebih rendah. MobileNetV1 menunjukkan nilai *loss* terendah pada konfigurasi 256 *neuron* di rasio 7:2:1, sedangkan MobileNetV2 memiliki nilai *loss* yang relatif stabil pada konfigurasi 64 *neuron* di kedua rasio pembagian data. Berdasarkan hasil tersebut, dapat disimpulkan bahwa MobileNetV2 dengan konfigurasi 64 *neuron* dan rasio 8:1:1 merupakan kombinasi terbaik untuk menghasilkan model klasifikasi penyakit daun padi yang akurat dan stabil, sekaligus memanfaatkan data pelatihan secara lebih optimal.


Evaluasi lanjutan terhadap performa masing-masing model dilakukan dengan menggunakan *confusion matrix* yang dapat dilihat pada Gambar (5-7).

Neuron 32




Gambar 1. Confusion Matrix MobileNet dengan 32 Neuron

Neuron 64



Gambar 2. Confusion Matrix MobileNet dengan 64 Neuron

Neuron 256



Gambar 3. Confusion Matrix MobileNet dengan 256 Neuron

Berdasarkan nilai yang didapatkan dari masing-masing model tersebut dapat dihitung nilai *accuracy*, *precision*, *recall*, dan *F1-Score*. Hasil perhitungan pada seluruh kelas untuk model MobileNetV1 dengan *neuron dense* 32, 64, 256 serta rasio 7:2:1 dan rasio 8:1:1 dapat dilihat Tabel (4-9).

TABEL IV. HASIL PERHITUNGAN SELURUH KELAS UNTUK MODEL MOBILENETV1 32 NEURON DENSE RASIO 7:2:1

Kelas	Accuracy	Precision	Recall	F1-Score
Blast	0,9375	0,90	0,83	0,86
Brown spot	0,9575	0,86	0,95	0,90
Hispa	0,9625	0,95	0,97	0,96
Healthy	0,9525	0,93	0,91	0,92

TABEL V. HASIL PERHITUNGAN SELURUH KELAS UNTUK MODEL MOBILENETV1 32 NEURON DENSE RASIO 8:1:1

Kelas	Accuracy	Precision	Recall	F1-Score
Blast	0,9750	0,97	0,76	0,85
Brown spot	0,9650	0,90	0,98	0,94
Hispa	0,990	0,98	0,89	0,93
Healthy	0,9750	0,85	0,98	0,91

TABEL VI. HASIL PERHITUNGAN SELURUH KELAS UNTUK MODEL MOBILENETV1 64 NEURON DENSE RASIO 7:2:1

Kelas	Accuracy	Precision	Recall	F1-Score
Blast	0,9650	0,86	0,81	0,83
Brown spot	0,9675	0,85	0,93	0,89
Hispa	0,9700	0,98	0,93	0,96
Healthy	0,9700	0,91	0,93	0,92

TABEL VII. HASIL PERHITUNGAN SELURUH KELAS UNTUK MODEL MOBILENETV1 64 NEURON DENSE RASIO 8:1:1

Kelas	Accuracy	Precision	Recall	F1-Score
Blast	0,9800	0,93	0,84	0,88
Brown spot	0,9700	0,94	0,96	0,95

Hispa	0,9900	0,98	0,96	0,97
Health y	0,9750	0,85	0,96	0,90

TABEL VIII. HASIL PERHITUNGAN SELURUH KLAS UNTUK MODEL MOBILENETV1 256 NEURON DENSE RASIO 7:2:1

Kelas	Accurac y	Precisio n	Recal l	F1- Scor e
Blast	0,9555	0,92	0,92	0,92
Brown spot	0,97	0,98	0,90	0,93
Hispa	0,98	0,97	0,97	0,97
Health y	0,93	0,86	0,86	0,86

TABEL IX. HASIL PERHITUNGAN SELURUH KLAS UNTUK MODEL MOBILENETV1 256 NEURON DENSE RASIO 8:1:1

Kelas	Accurac y	Precisio n	Recal l	F1- Scor e
Blast	0,96	0,96	0,88	0,91
Brown spot	0,975	0,93	0,98	0,95
Hispa	0,96	0,92	0,92	0,92
Health y	0,96	0,90	0,94	0,92

Hasil perhitungan pada seluruh kelas untuk model MobileNetV2 dengan *neuron dense* 32, 64, 256 serta rasio 7:2:1 dan rasio 8:1:1 dapat dilihat Tabel (10-15).

TABEL X. HASIL PERHITUNGAN SELURUH KLAS UNTUK MODEL MOBILENETV2 32 NEURON DENSE RASIO 7:2:1

Kelas	Accurac y	Precisio n	Recal l	F1- Scor e
Blast	0,9550	0,92	0,73	0,81
Brown spot	0,9575	0,82	0,94	0,88
Hispa	0,9775	0,93	0,96	0,95
Health y	0,9675	0,94	0,91	0,92

TABEL XI. HASIL PERHITUNGAN SELURUH KLAS UNTUK MODEL MOBILENETV2 32 NEURON DENSE RASIO 8:1:1

Kelas	Accurac y	Precisio n	Recal l	F1- Scor e
Blast	0,9800	0,98	0,75	0,85

Brown spot	0,9750	0,79	0,96	0,87
Hispa	0,9850	0,94	0,95	0,95
Health y	0,9850	0,92	0,87	0,89

TABEL XII. HASIL PERHITUNGAN SELURUH KLAS UNTUK MODEL MOBILENETV1 64 NEURON DENSE RASIO 7:2:1

Kelas	Accurac y	Precisio n	Recal l	F1- Scor e
Blast	0,9600	0,90	0,88	0,89
Brown spot	0,9650	0,93	0,94	0,94
Hispa	0,9750	0,93	0,90	0,92
Health y	0,9750	0,92	0,96	0,94

TABEL XIII. HASIL PERHITUNGAN SELURUH KLAS UNTUK MODEL MOBILENETV1 64 NEURON DENSE RASIO 8:1:1

Kelas	Accurac y	Precisio n	Recal l	F1- Scor e
Blast	0,9850	0,96	0,93	0,94
Brown spot	0,9800	0,93	0,90	0,92
Hispa	0,9900	0,94	0,96	0,95
Health y	0,9850	0,91	0,87	0,89

TABEL XIV. HASIL PERHITUNGAN SELURUH KLAS UNTUK MODEL MOBILENETV1 256 NEURON DENSE RASIO 7:2:1

Kelas	Accurac y	Precisio n	Recal l	F1- Scor e
Blast	0,9275	0,85	0,86	0,86
Brown spot	0,9575	0,94	0,89	0,92
Hispa	0,965	0,95	0,95	0,95
Health y	0,965	0,91	0,95	0,93

TABEL XV HASIL PERHITUNGAN SELURUH KLAS UNTUK MODEL MOBILENETV1 256 NEURON DENSE RASIO 8:1:1

Kelas	Accurac y	Precisio n	Recal l	F1- Scor e
Blast	0,95	0,88	0,92	0,90
Brown spot	0,965	0,96	0,90	0,93
Hispa	0,97	0,94	0,94	0,94

Health y	0,97	0,92	0,96	0,94
-------------	------	------	------	------

Hasil evaluasi secara keseluruhan menunjukkan bahwa model MobileNetV2 dengan konfigurasi 64 *neuron dense* dan rasio 8:1:1 merupakan model terbaik dibandingkan model lainnya, karena memiliki nilai akurasi validasi, *precision*, *recall*, dan *f1-score* rata-rata yang paling seimbang dan konsisten pada setiap kelas.

Jika dibandingkan dengan penelitian sebelumnya, misalnya penerapan NasNet Mobile dan MobileNet pada klasifikasi penyakit daun kentang dengan akurasi masing-masing 90,86% dan 81,60% [12], hasil penelitian ini menunjukkan peningkatan performa khususnya pada MobileNetV2 yang mampu mencapai akurasi 93,50%. Perbedaan hasil ini dapat dipengaruhi oleh karakteristik dataset yang digunakan, jumlah data, serta teknik preprocessing dan augmentasi yang diterapkan. MobileNetV2 juga didesain dengan inverted residual block dan linear bottleneck yang membuatnya lebih efisien dalam mengekstraksi fitur kompleks dibandingkan MobileNetV1.

4. KESIMPULAN DAN SARAN

Berdasarkan hasil implementasi dan pengujian yang telah dilakukan, dapat disimpulkan bahwa metode MobileNet efektif digunakan dalam klasifikasi penyakit tanaman daun padi berbasis citra. Rata-rata akurasi yang diperoleh dari keempat model, yaitu MobileNetV1 dan MobileNetV2 dengan rasio pembagian data 7:2:1 dan 8:1:1, mencapai 91,88%. Model terbaik dalam penelitian ini adalah MobileNetV2 dengan konfigurasi 64 *neuron* pada *dense layer* dan rasio data 8:1:1, karena menghasilkan performa evaluasi paling seimbang dengan akurasi validasi sebesar 93,50%, *precision* 92,51%, *recall* 92,95%, dan *F1-Score* 92,64%. Temuan ini mengindikasikan bahwa MobileNetV2 mampu memberikan hasil klasifikasi yang efisien dan akurat, serta berpotensi membantu petani dalam mendeteksi penyakit tanaman secara lebih cepat sehingga dapat mengurangi risiko penurunan hasil panen.

Saran untuk penelitian selanjutnya, peneliti dapat mengeksplorasi penggunaan struktur *fully connected layer* (FCL) yang berbeda, seperti menambahkan jumlah *neuron*, *layer* tambahan, atau memodifikasi fungsi aktivasi. Eksperimen terhadap kombinasi *optimizer*, *loss function*, dan *learning rate*, serta pengaturan parameter *training* seperti *batch size* dan jumlah *epoch* juga disarankan guna meningkatkan performa dan

stabilitas model. Selain itu, penggunaan arsitektur model lain seperti ResNet atau DenseNet yang memiliki kemampuan ekstraksi fitur lebih baik melalui *residual connection* atau *dense connectivity* dapat dipertimbangkan, khususnya untuk meningkatkan akurasi pada dataset berukuran kecil. Pengembangan lebih lanjut juga dapat dilakukan dalam bentuk aplikasi berbasis *website* atau *mobile* agar hasil penelitian ini dapat diimplementasikan secara langsung oleh pengguna akhir, khususnya petani.

5. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada teman-teman penulis sehingga penelitian ini dapat terlaksana dengan lancar.

Daftar Pustaka:

- [1] A. A. Wahditiya *et al.*, *Teknologi Produksi Tanaman Pangan*, 1st ed. Gadut: Yayasan Tri Edukasi Ilmiah, 2024.
- [2] B. Putra Aryadi and N. Hendrastuty, "PENERAPAN ALGORITMA K-MEANS UNTUK MELAKUKAN KLASIFIKASI PADA VARIETAS PADI," *Jurnal Informatika & Rekayasa Elektronika*, vol. 7, no. 1, 2024, [Online]. Available: <http://e-journal.stmiklombok.ac.id/index.php/jire> ISSN.2620-6900
- [3] S. Rudjua, I. Bempah, and Y. Saleh, "Mitigasi Perubahan Iklim Terhadap Usahatani Padi Sawah Desa Molombulahe Kecamatan Paguyaman Kabupaten Boalemo," *Economics and Digital Business Review*, vol. 5, no. 2, pp. 525–536, Mar. 2024, doi: 10.37531/ecotal.v5i2.956.
- [4] A. R. Salasa, "Paradigma dan dimensi strategi ketahanan pangan Indonesia," *Jejaring Administrasi Publik*, vol. 13, no. 1, pp. 35–48, 2021.
- [5] B. E. Cahyono, R. Rahagian, and A. T. Nugroho, "Analisis Produktivitas Padi berdasarkan Indeks Kekeringan (NDWI dan NDDI) Lahan Sawah menggunakan Data Citra Sentinel-2A di Kecamatan Ambulu," *Indonesian Journal Of Applied Physics*, vol. 13, no. 1, pp. 88–98, 2023.
- [6] M. I. N. Syahputra, "Pengelolaan Diagnosis Penyakit Tanaman Padi Menggunakan Metode Teorema Bayes (Studi Kasus : Kec. Sukowono)," *JIKO (Jurnal Informatika dan Komputer)*, vol. 8, no. 2, p. 393, Sep. 2024, doi: 10.26798/jiko.v8i2.1315.

- [7] F. Sulistiyana and S. Anardani, "Aplikasi Deteksi Penyakit Tanaman Jagung Dengan Metode CNN dan SVM," in *Prosiding Seminar Nasional Teknologi Informasi dan Komunikasi (SENATIK)*, 2024, pp. 423–432.
- [8] Y. Ginting, K. Hantoro, and A. Y. P. Yusuf, "Deteksi Jenis Sampah Plastik Berbasis Mobile Menggunakan Model Transfer Learning," *Jurnal Ilmiah Teknik Informatika (TEKINFO)*, vol. 25, no. 2, pp. 110–119, 2024.
- [9] R. Rikendry and A. Maharil, "Perbandingan Arsitektur Vgg16 Dan Resnet50 Untuk Rekognisi Tulisan Tangan Aksara Lampung," *Jurnal Informatika dan Rekayasa Perangkat Lunak*, vol. 3, no. 2, pp. 236–243, 2022.
- [10] D. Carlos, D. Erny Herwindiati, and C. Lubis, "Implementasi Algoritma Convolutional Neural Networks Untuk Klasifikasi Jenis Cat Tembok Menggunakan Arsitektur MobileNet," *Technology and Science (BITS)*, vol. 6, no. 1, 2024, doi: 10.47065/bits.v6i1.5322.
- [11] A. Ridhovan and A. Suharso, "Penerapan Metode Residual Network (RESNET) Dalam Klasifikasi Penyakit Pada Daun Gandum," *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, vol. 7, no. 1, pp. 58–65, 2022.
- [12] A. Fuadi and A. Suharso, "Perbandingan Arsitektur MobileNet Dan NasNetMobile Untuk Klasifikasi Penyakit Pada Citra Daun Kentang," *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 7, no. 3, pp. 701–710, Aug. 2022, doi: 10.29100/jupi.v7i3.3026.
- [13] F. R. Anugrah, F. Bimantoro, and I. G. P. S. Wijaya, "Klasifikasi Ikan Cakalang Dan Ikan Tongkol Menggunakan Xception Dan Mobilenet," *Jurnal Teknologi Informasi, Komputer, dan Aplikasinya (JTika)*, vol. 7, no. 1, pp. 13–24, 2025.
- [14] I. Muraina, "Ideal dataset splitting ratios in machine learning algorithms: general concerns for data scientists and data analysts," in *7th international Mardin Artuklu scientific research conference*, 2022, pp. 496–504.
- [15] Didi Kurniawan and Dhani Ariatmanto, "Identifikasi Varietas Bibit Durian Menggunakan MobileNetV2 Berdasarkan Gambar Daun," *Jurnal Informatika dan Rekayasa Elektronik*, vol. 7, no. 2, pp. 231–240, Nov. 2024, doi: 10.36595/jire.v7i2.1236.
- [16] M. F. Naufal and S. F. Kusuma, "Pendeteksi citra masker wajah menggunakan CNN dan transfer learning," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, vol. 8, no. 6, pp. 1293–1300, 2021.
- [17] W. Astriningsih, "Identifikasi Multi Aspek Dan Sentimen Analisis Pada Review Hotel Menggunakan Deep Learning," Universitas Islam Indonesia, 2023.