

# KLASIFIKASI PENYAKIT DAUN PADI MENGGUNAKAN MODEL DEEP LEARNING EFFICIENTNET-B6

Amanda Caecilia Milano<sup>1\*</sup>, Achmad Yasid<sup>2</sup>, Rima Tri Wahyuningrum<sup>3</sup>

<sup>1,2,3</sup> Teknik Informatika, Universitas Trunojoyo Madura; Bangkalan, Jawa Timur, Indonesia

---

## Riwayat artikel:

Received: 22 November 2022

Accepted: 29 Desember 2023

Published: 1 Januari 2024

## Keywords:

Klasifikasi;  
Daun padi;  
Citra;  
CNN;  
EfficientNet-B6.

## Correspondent Email:

amandacaeciliam03@gmail.com

**Abstrak.** Tanaman padi merupakan tanaman pangan utama di Indonesia. Tanaman ini diolah menjadi beras dan menjadi makanan utama sehari-hari seluruh masyarakat Indonesia. Pertumbuhan tanaman padi sangat penting untuk menjaga kualitas padi yang baik dan aman untuk dikonsumsi. Salah satu bagian tanaman padi yang mudah terserang penyakit yaitu daun tanaman padi, hal tersebut bisa mempersulit pertumbuhan tanaman padi dan menjadikan kualitas tanaman padi menurun. Metode *Convolutional Neural Network* dengan menggunakan arsitektur *EfficientNet-B6* merupakan metode yang dapat digunakan untuk klasifikasi gambar atau citra yang mana bisa membantu untuk mengetahui penyakit tanaman padi dan melakukan pencegahan dan pemeliharaan tanaman padi lebih lanjut. Pada penelitian ini menggunakan 3355 citra daun tanaman padi yang dibagi menjadi empat kelas yaitu *Healthy* sebanyak 1488 citra, *LeafBlast* sebanyak 779 citra, *Hispa* sebanyak 565 citra, dan *BrownSpot* sebanyak 523 citra. Klasifikasi dilakukan menggunakan metode *Deep Learning* dengan arsitektur *EfficientNet-B6* dan diperoleh hasil kinerja terbaik yakni pada skenario dengan nilai *size input* = 224 dan jumlah *epoch* = 50, hasil akurasi tertinggi ada pada *fold* yang kelima dengan nilai akurasi sebesar 77.05%, presisi 77.11%, *recall* 77.05%, dan *f1 score* 76.29%. Serta, nilai AUC yang didapatkan skenario 2 juga paling optimal dengan nilai setiap *fold* dengan *range* 0.90 – 0.93.

**Abstract.** The rice plant is the main food crop in Indonesia. This plant is processed into rice and serves as the staple food for the entire Indonesian population. The growth of rice plants is crucial to maintaining good quality and safe-to-consume rice. One part of the rice plant that is susceptible to diseases is the leaves, which can hinder the growth of rice plants and reduce the overall quality of the rice. The Convolutional Neural Network (CNN) method, using the EfficientNet-B6 architecture, is a technique that can be employed for image or leaf classification, aiding in the identification of rice plant diseases and facilitating further prevention and maintenance. This research utilized 3355 images of rice plant leaves, categorized into four classes: Healthy with 1488 images, LeafBlast with 779 images, Hispa with 565 images, and BrownSpot with 523 images. The classification was conducted using the Deep Learning method with the EfficientNet-B6 architecture, and the best performance was achieved in the scenario with an input size of 224 and 50 epochs. The highest accuracy was obtained in the fifth fold, with an accuracy value of 77.05%, precision of 77.11%, recall of 77.05%, and an F1 score of 76.29%. Additionally, the AUC values obtained in scenario 2 were also optimal, ranging from 0.90 to 0.93 for each fold.

## 1. PENDAHULUAN

Tanaman padi menghasilkan beras sebagai makanan pokok yang sering dikonsumsi di Indonesia, sehingga hal yang sangat berpengaruh yaitu kesuksesan jumlah tanaman padi yang dipanen. Keterlambatan dalam proses diagnosis secara manual menyebabkan penyakit pada tanaman padi bisa mencapai tahap yang parah, mengakibatkan gagal panen karena kurangnya pengetahuan petani dan persepsi bahwa gejala yang muncul pada daun tanaman padi adalah hal yang biasa selama musim tanam. Daripada hanya melakukan kontrol saat serangan hama telah terjadi, lebih baik adalah melakukan tindakan pencegahan [1]. Mengidentifikasi jenis penyakit dan mengenali ciri-ciri penyakit merupakan langkah awal yang krusial dalam menentukan keberhasilan upaya pengelolaan penyakit yang efektif, aman, dan efisien. Hingga saat ini, penyuluh pertanian masih menghadapi tantangan dalam mengenali penyakit yang menyerang tanaman padi, meskipun terdapat perubahan yang terlihat pada tanaman tersebut. Oleh karena itu, mereka kesulitan menentukan solusi atau metode penanganan yang tepat untuk mengatasi penyakit tersebut. Dampaknya, penyuluh juga mengalami kesulitan dalam menjelaskan kepada petani mengenai gejala-gejala yang muncul pada tanaman yang terinfeksi penyakit [2]. Identifikasi tanaman merupakan proses membandingkan fitur tanaman dari spesimen yang di kumpulkan dan dikategorikan sebelumnya. Banyak sekali organ tumbuhan yang dapat digunakan untuk mengidentifikasi spesies tumbuhan misalnya, bunga, daun, batang, buah atau bahkan seluruh tanamannya, namun fitur khas tanaman adalah daun. Terdapat lebih dari 100 studi telah menggunakan gambar daun untuk mengidentifikasi tumbuhan [3].

Teknologi kecerdasan buatan (AI) memiliki peran yang signifikan dalam meningkatkan ketahanan tanaman pangan di sektor pertanian. Salah satu perkembangan terkini dalam AI adalah pemanfaatan pengenalan objek melalui citra atau gambar dalam konteks pertanian. Teknik yang banyak digunakan dalam pengenalan gambar atau objek digital adalah klasifikasi, dengan salah satu pendekatan utamanya adalah penggunaan jaringan saraf tiruan (JST). *Deep learning* saat ini menjadi salah satu alat utama untuk memprediksi

peluang, mengenali objek, dan mendiagnosis penyakit. Sistem pemrosesan gambar ini bertujuan membantu mengidentifikasi dan mengklasifikasikan objek gambar dengan akurasi, kecepatan, dan efisiensi tinggi, bahkan dalam volume yang besar. Metode *Convolutional Neural Network* (CNN) merupakan salah satu metode *image processing* yang banyak digunakan karena tingkat akurasi yang tinggi [4].

*Convolutional Neural Networks* (CNN) sangat cocok untuk melakukan tugas pemrosesan suatu gambar, lapisan konvolusional ini merupakan suatu bangunan jaringan saraf konvolusional yang terdiri dari beberapa filter yang digabungkan dengan gambar dan melakukan input dari lapisan konvolusional sebelumnya sehingga terhubung sepenuhnya menjadi output layer, yang mirip dengan respon neuron di otak untuk merangsang organisme bagian tubuh tertentu menjadi aktif [5]. Terdapat beberapa arsitektur CNN saat ini contohnya seperti *AlexNet*, *GoogleNet*, *ResNet*, *NasNet*, dan *EfficientNet* [6].

Arsitektur *EfficientNet* merupakan salah satu model klasifikasi gambar yang cukup canggih dengan akurasi mencapai 84,4%. *EfficientNet* memiliki 8 model yang dimulai dari B0 sampai B7 yang mana dengan meningkatnya nomor pada model maka parameternya juga bertambah, dan akurasi terus menerus meningkat [7]. Banyaknya metode CNN yang ada, dapat dibandingkan tingkat akurasi yang paling tinggi diantaranya, salah satu jurnal berjudul "*Classification of Beans Leaf Diseases using Fine Tuned CNN Model*" membahas klasifikasi penyakit daun buncis menggunakan beberapa model CNN yaitu *EfficientNet-B6*, *MobileNet-V2*, dan *NasNet* yang mana menghasilkan akurasi tertinggi dengan menggunakan model *EfficientNet-B6* [8]. Serta jurnal berjudul "Klasifikasi Citra Daging Sapi dan Daging Babi Menggunakan CNN Arsitektur *EfficientNet-B6* dan Augmentasi Data" menggunakan metode CNN arsitektur *EfficientNet-B6* untuk melakukan klasifikasi citra [9]. Dari paparan latar belakang tersebut maka dalam penelitian ini akan mengimplementasikan metode *Deep Learning* untuk mengklasifikasikan penyakit tanaman padi dari gambar daun padi menggunakan *Convolutional Neural Network* (CNN) dengan

menggunakan arsitektur *EfficientNet-B6* dengan tujuan memudahkan klasifikasi penyakit dari citra daun tanaman padi dengan proses yang akurat.

## 2. TINJAUAN PUSTAKA

### 2.1 Penyakit Pada Daun Padi

Padi merupakan komoditas utama di Indonesia karena merupakan tanaman pangan yang setiap hari di konsumsi. Varietas tanaman adalah salah satu faktor yang cukup mempengaruhi adanya penyakit, pertumbuhan dan hasil produksi. Setiap varietas memiliki ketahanan yang berbeda pada setiap penyakit [10]. Berikut beberapa penyakit pada tanaman padi:

#### 1. *Leaf Blast*

Penyakit ini ditandai dengan adanya bercak yang pada bagian ujungnya berbentuk runcing, pada bagian tepi bercak ini berwarna coklat dan pada bagian pusat bercak berwarna kelabu atau keputih-putihan. Bercak akan terus berkembang dan bagian samping bercak akan dikelilingi warna kuning pucat [11].

#### 2. Hispa

Penyakit hispa ini terjadi akibat serangan serangga dewasa yang mengikis permukaan daun sehingga menyebabkan terjadinya pola garis-garis putih di sepanjang daun padi [1].

#### 3. *Brown Spot*

Penyakit ini ditandai dengan adanya bercak coklat kecil di dalam satu helai daun padi, yang mana bercak tersebut berwarna coklat tua dengan warna coklat lebih muda di bagian tepinya [11]. Penyakit ini disebabkan oleh jamur *Helminthosporium oryzae* atau *Drechslera oryzae* (*Cochliobolus miyabeanus*), penyakit ini biasanya disebarkan oleh angin dan dapat menyebabkan kematian terhadap tanaman atau menyebabkan kualitas tanamanan menurun [12].

### 2.2 Klasifikasi

Klasifikasi adalah langkah untuk mengidentifikasi pola yang memungkinkan pengelompokan data berdasarkan kategori atau kelasnya, dan hal ini dapat dicapai dengan menggunakan teknik *machine learning* yang melakukan pembelajaran dari data sejarah

(*historical data*). Dalam kehidupan ada banyak objek yang diharuskan untuk dikategorikan dalam suatu kelompok berdasarkan sifat dari objek-objek tersebut. Teknik klasifikasi dapat digunakan untuk membedakan dan mengidentifikasi jenis-jenis penyakit berdasarkan gejala yang hadir [13].

### 2.3 Deep Learning

*Deep learning* adalah metode *machine learning* yang melibatkan sejumlah besar lapisan dalam jaringan saraf tiruan, yang digunakan untuk mengolah data secara berurutan. *Deep learning* merupakan subbagian dari *machine learning* yang memanfaatkan *neural network* untuk menyelesaikan berbagai masalah [8].

### 2.4 CNN

*Convolutional Neural Network* (CNN), yang merupakan algoritma yang sangat penting dalam pengenalan citra digital karena didasarkan pada konsep citra dalam visual *cortex* manusia [4].

CNN merupakan salah satu model *deep learning* yang memiliki dua struktur layer yaitu *feature learning* dan *classification (fully connected layer)* [14]. Lengkapinya struktur CNN mencakup *input*, tahap ekstraksi fitur, tahap klasifikasi, dan *output*. Tahap ekstraksi dalam CNN terdiri dari beberapa lapisan tersembunyi, termasuk lapisan konvolusi, fungsi aktivasi ReLU, dan lapisan *pooling*. CNN beroperasi secara hierarkis, di mana hasil dari lapisan konvolusi awal digunakan sebagai input untuk lapisan konvolusi berikutnya. Pada tahap klasifikasi, terdapat lapisan *fully connected* dan penggunaan fungsi aktivasi *softmax* yang menghasilkan *output* berupa hasil klasifikasi [15].

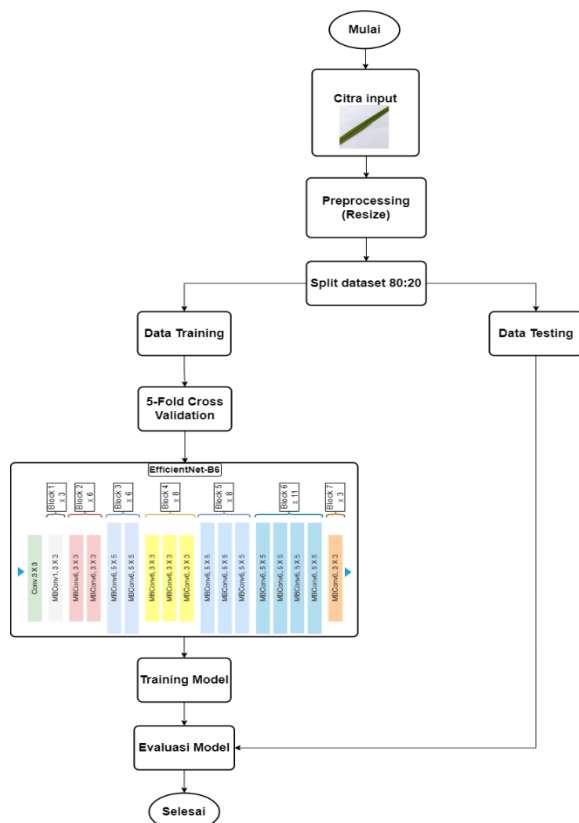
### 2.5 EfficientNet-B6

*EfficientNet* adalah serangkaian arsitektur *Convolutional Neural Network* (CNN) yang dikembangkan oleh Mingxing Tan dan Quoc V. Le dari *Google Brain* pada tahun 2019. *EfficientNet* memanfaatkan teknik konvolusi *depthwise* dan *pointwise*. Terdapat tiga dimensi penskalaan yang digunakan dalam *EfficientNet*, yakni kedalaman (*depth*), lebar (*width*), dan resolusi (*resolution*). Secara keseluruhan, model *EfficientNet* menghasilkan tingkat akurasi yang tinggi dan kinerja yang lebih

unggul jika dibandingkan dengan model-model CNN lainnya. *EfficientNet* terdiri dari 7 blok, di mana setiap blok memiliki berbagai sub-blok yang beragam. Metode ini menggunakan koefisien gabungan untuk menyesuaikan skala lebar, kedalaman, dan resolusi jaringan dengan seragam [16].

*EfficientNet-B6* adalah model yang diterapkan dalam rangkaian *EfficientNet* CNN yang diusulkan oleh Google di tahun 2019 yang berfokus pada peningkatan akurasi dan efisiensi model, *EfficientNet-B6* merupakan peningkatan skala dari *EfficientNet-B0* sebanyak 8 kali lipat dalam hal jumlah parameternya [17]

### 3. METODE PENELITIAN



Gambar 1. Arsitektur Sistem

Berdasarkan arsitektur sistem pada Gambar 1. terdapat 6 tahapan utama dalam penelitian ini yaitu *input* data citra, kemudian melakukan *preprocessing* dengan cara *resize* ukuran citra *input*, setelah *preprocessing* kemudian *dataset* dipisahkan menjadi dua bagian yaitu data pelatihan (*training*) dan data pengujian (*testing*) dengan perbandingan 80:20 kemudian data *training* dipisah menjadi 5 bagian dengan

menggunakan teknik validasi silang 5-kali (*5-fold cross validation*), selanjutnya masuk ke tahap *modelling* menggunakan model *EfficientNet-B6*, kemudian dilakukan *testing* data menggunakan model dari hasil data *training*, dan tahap terakhir yaitu melakukan evaluasi model.

#### 3.1 Dataset

Data citra daun padi ini diperoleh dari situs Kaggle dengan judul “Rice Leafs”. Pada dataset terdapat empat kelas yaitu *LeafBlast*, *Hispa*, *BrownSpot*, dan *Healthy* dengan jumlah total data sebanyak 3.355. Contoh citra keempat jenis daun padi ini dapat dilihat pada Gambar 2.



Gambar 2. Contoh Dataset

Jumlah data pada masing-masing kelas dapat dilihat pada Tabel 1.

Tabel 1. Jumlah Dataset

Kelas	Jumlah
<i>Healthy</i>	1488
<i>Leaf Blast</i>	779
<i>Hispa</i>	565
<i>Brown Spot</i>	523
<b>Total</b>	<b>3.355</b>

#### 3.2 Modelling

Pada tahap ini dilakukan pemodelan data untuk melakukan klasifikasi citra ini menggunakan arsitektur model cnn yaitu *EfficientNet-B6*. Adapun skenario yang akan diujicobakan untuk meningkatkan akurasi pada model yaitu dengan melakukan perbandingan untuk mencari parameter terbaik dengan penentuan *size* citra *input* serta nilai *learning rate* yang digunakan berdasarkan tabel berikut:

Tabel 2. Skenario Uji Coba

<i>Size Input</i>	<i>Epoch</i>
224	25
	50
528	25
	50

### 3.3 Evaluasi

#### 3.3.1 Confusion matrix

*Confusion matrix* digunakan dalam analisis klasifikasi untuk mengevaluasi kinerja model atau keakuratan hasil klasifikasi.

Pengukuran kinerja dengan menggunakan *confusion matrix* ini mempunyai empat hasil pengukuran yakni:

1. *True Positive* (TP): Jumlah data yang benar-benar positif dan diprediksi dengan benar sebagai positif oleh model.
2. *True Negative* (TN): Jumlah data yang benar-benar negatif dan diprediksi dengan benar sebagai negatif oleh model.
3. *False Positive* (FP): Jumlah data yang sebenarnya negatif tetapi salah diprediksi sebagai positif oleh model, dikenal sebagai kesalahan tipe I.
4. *False Negative* (FN): Jumlah data yang sebenarnya positif tetapi salah diprediksi sebagai negatif oleh model, dikenal sebagai kesalahan tipe II.

*Confusion Matrix* membantu dalam mengukur berbagai metrik evaluasi kinerja model, termasuk perhitungan performa dilakukan di setiap tahapan *cross validation* dan nilai performanya dirata-rata. Berikut beberapa rumus yang diterapkan dalam mengevaluasi performa dari model [18]:

Akurasi (*accuracy*) merupakan rasio prediksi benar (positif dan negatif) dengan keseluruhan data atau nilai ketepatan nilai prediksi dengan nilai sebenarnya. Nilai *accuracy* dapat diperoleh dengan persamaan (2).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

Presisi (*precision*) merupakan rasio prediksi benar dengan positif keseluruhan hasil

yang diprediksi positif. Nilai *precision* dapat diperoleh dengan persamaan (3).

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

*Recall* merupakan rasio prediksi benar positif dibandingkan dengan keseluruhan data yang benar positif. Nilai *recall* dapat diperoleh dengan persamaan (4).

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

*F1-Score* merupakan perbandingan rata-rata *precision* dan *recall*. ketika data yang tidak seimbang (*imbalance class*) metrik ini menggabungkan *precision* dan *recall* menjadi satu nilai tunggal yang memberikan gambaran tentang kinerja model klasifikasi. Nilai *f1-Score* dapat diperoleh dengan persamaan (5).

$$F1 - Score = 2 \times \frac{Recall * Precision}{Recall + Precision} \quad (5)$$

#### 3.3.2 Kurva ROC

*Receiver Operating Characteristic* (ROC) merupakan sebuah grafik atau kurva probabilitas yang mengukur luas area di bawah kurva tersebut dengan AUC (*Area Under the Curve*). Maksimal AUC adalah 1, menandakan bahwa model klasifikasi tersebut adalah yang paling sempurna.

## 4. HASIL DAN PEMBAHASAN

Terdapat 4 skenario pengujian pada penelitian dalam menentukan kombinasi parameter terbaik untuk mengetahui nilai akurasi terbaik pada rancangan model *EfficientNet-B6*. Tujuan dari penelitian ini yakni mengetahui pengaruh nilai akurasi, presisi, *recall* dan *f1 score* dengan variasi nilai *size input* dan jumlah *epoch* pada metode *efficientNet-B6* dalam klasifikasi penyakit pada citra daun padi.

#### 4.4.1 Skenario uji coba 1

Hasil uji coba skenario 1 dengan model *EfficientNet-B6* dengan kombinasi *size input* = 224 dan jumlah *epoch*=25 dapat dilihat hasil akurasi, presisi, *recall*, dan *f1 score* pada Tabel 3.

Tabel 3. Hasil skenario uji coba 1

	Akurasi	Presisi	Recall	f1-Score
<b>fold 1</b>	74.52	74.19	74.52	73.90
<b>fold 2</b>	74.37	74.01	74.37	73.39
<b>fold 3</b>	70.34	70.59	70.34	70.10
<b>fold 4</b>	74.22	74.10	74.22	72.69
<b>fold 5</b>	73.03	72.58	73.03	71.97

Pada skenario 1 hasil akurasi, presisi, *recall* dan *f1 score* memperoleh nilai paling optimal pada *fold 1* dengan nilai akurasi = 74.52%, presisi = 74.19%, *recall* = 74.52%, dan *f1 score* = 73.90%. Dan nilai rata-rata dari pengukuran pada skenario ini yakni, akurasi = 73.29%, presisi = 73.09%, *recall* = 73.29%, dan *f1 score* = 72.41%.

#### 4.4.2 Skenario uji coba 2

Hasil uji coba skenario 2 dengan model *EfficientNet-B6* dengan kombinasi *size input* = 224 dan jumlah *epoch*=50, dapat dilihat hasil akurasi, presisi, *recall*, dan *f1 score* pada Tabel 4.

Tabel 4. Hasil skenario uji coba 2

	Akurasi	Presisi	Recall	f1-Score
<b>fold 1</b>	74.81	74.01	74.81	73.71
<b>fold 2</b>	74.96	74.49	74.96	74.53
<b>fold 3</b>	70.94	70.36	70.94	69.98
<b>fold 4</b>	73.32	72.78	73.32	72.92
<b>fold 5</b>	77.05	77.11	77.05	76.29

Pada skenario 2 hasil akurasi, presisi, *recall* dan *f1 score* memperoleh nilai paling optimal pada *fold 5* dengan nilai akurasi = 77.05%, presisi = 77.11%, *recall* = 77.05%, dan *f1 score* = 76.29%. Dan nilai rata-rata dari pengukuran pada skenario ini yakni, akurasi = 74.22%, presisi = 73.75%, *recall* = 74.22%, dan *f1 score* = 73.49%.

#### 4.4.3 Skenario uji coba 3

Hasil uji coba skenario 3 dengan model *EfficientNet-B6* dengan kombinasi *size input* = 528 dan jumlah *epoch*=25 dapat dilihat hasil akurasi, presisi, *recall*, dan *f1 score* pada Tabel 5.

Tabel 5. Hasil skenario uji coba 3

	Akurasi	Presisi	Recall	f1-Score
<b>fold 1</b>	74.37	76.31	74.37	73.45
<b>fold 2</b>	71.39	73.41	71.39	70.54
<b>fold 3</b>	72.43	75.88	72.43	70.96
<b>fold 4</b>	74.81	76.69	74.81	74.05
<b>fold 5</b>	73.92	76.60	73.92	73.82

Pada skenario 3 hasil akurasi, presisi, *recall* dan *f1 score* memperoleh nilai paling optimal pada *fold 4* dengan nilai akurasi = 74.81%, presisi = 76.69%, *recall* = 74.81%, dan *f1 score* = 74.05%. Dan nilai rata-rata dari pengukuran pada skenario ini yakni, akurasi = 73.38%, presisi = 75.78%, *recall* = 73.38%, dan *f1 score* = 72.56%.

#### 4.4.4 Skenario uji coba 4

Hasil uji coba skenario 4 dengan model *EfficientNet-B6* dengan kombinasi *size input* = 528 dan jumlah *epoch*=50 dapat dilihat hasil akurasi, presisi, *recall*, dan *f1 score* pada Tabel 6.

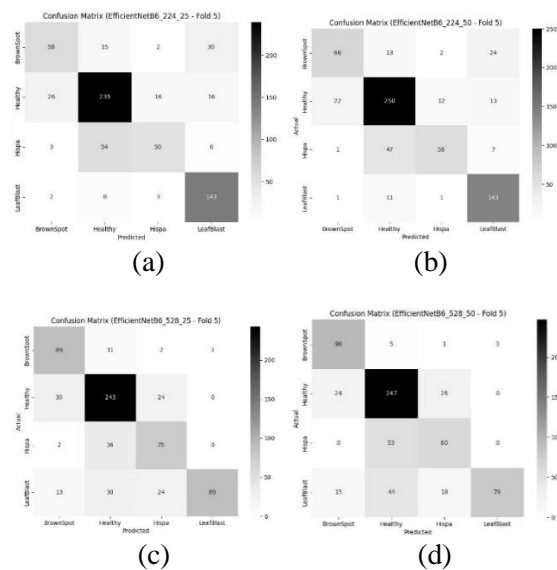
Tabel 6. Hasil skenario uji coba 4

	Akurasi	Presisi	Recall	f1-Score
<b>fold 1</b>	72.28	74.87	72.28	71.24
<b>fold 2</b>	76.90	79.96	76.90	75.75
<b>fold 3</b>	73.62	76.99	73.62	72.44
<b>fold 4</b>	75.26	78.41	75.26	74.50
<b>fold 5</b>	71.83	74.48	71.83	71.07

Pada skenario 4 hasil akurasi, presisi, *recall* dan *f1 score* memperoleh nilai paling optimal pada *fold 2* dengan nilai akurasi = 76.90%, presisi = 79.96%, *recall* = 76.90%, dan *f1 score* = 75.75%. Dan nilai rata-rata dari pengukuran pada skenario ini yakni, akurasi = 73.98%, presisi = 76.94%, *recall* = 73.98%, dan *f1 score* = 73.00%. Pada Gambar 4.5 menunjukkan hasil *plotting confusion matrix* dari *fold 5* pada skenario 4.

Dari hasil skenario uji coba 1-4 yang telah dipaparkan dapat dilihat bahwa nilai akurasi yang didapatkan cukup bagus. Nilai akurasi paling tinggi mencapai 77.05% pada skenario uji coba yang ke-2 di *fold* yang ke-5 dengan nilai *size input* = 224 serta jumlah *epoch* = 50.

Namun nilai tersebut tidak jauh dengan nilai dari skenario lainnya. Jika dilihat dari hasil *plot confusion matrix* banyak prediksi yang salah pada kelas Hispa dan juga *LeafBlast* baik dari skenario uji coba 1 sampai skenario uji coba 4. Pada kelas Hispa model banyak memprediksi menjadi kelas *Healthy*, dan pada kelas *LeafBlast* model banyak memprediksi menjadi ketiga kelas lainnya yakni *Healthy*, *BrownSpot*, dan Hispa.



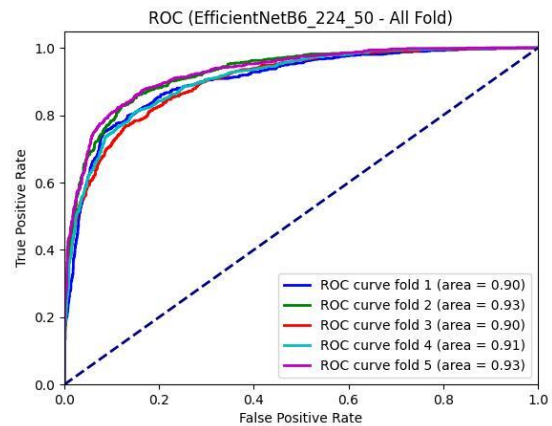
Gambar 3 *Confusion Matrix* pada setiap skenario: (a) skenario 1, (b) skenario 2, (c) skenario 3, (d) skenario 4

Pada Tabel 7 semua model memperoleh nilai akurasi yang dekat satu sama lain. Pada fold 5 nilai tertinggi yaitu sebesar 77,05% di skenario yang ke-2.

Tabel 7. Rangkuman hasil akurasi uji coba

	fold 1	fold 2	fold 3	fold 4	fold 5
	%	%	%	%	%
1	74.52	74.37	70.34	74.22	73.03
2	74.81	74.96	70.94	73.32	<b>77.05</b>
3	74.37	71.39	72.43	74.81	73.92
4	72.28	76.9	73.62	75.26	71.83

Kurva ROC untuk setiap *fold* pada skenario kedua yang mendapat hasil nilai dengan *range* 0.90 sampai 0.93. Kuva ROC tersebut dapat dilihat pada Gambar 4.



Gambar 4. Kurva ROC skenario 2

### 5. KESIMPULAN

Dalam penelitian ini model *deep learning EfficientNet-B6* digunakan untuk melakukan klasifikasi citra penyakit daun padi yang memiliki 4 kelas. Berdasarkan hasil analisis yang telah dilakukan, diperoleh hasil kinerja terbaik yakni pada skenario 2 dengan nilai *size input* = 224 dan jumlah *epoch* = 50, hasil akurasi tertinggi ada pada *fold* yang kelima dengan nilai akurasi sebesar 77.05%, presisi 77.11%, *recall* 77.05%, dan *f1 score* 76.29%. Serta, nilai AUC yang didapatkan skenario 2 juga paling optimal dengan nilai setiap *fold*nya dengan *range* 0.90 – 0.93. Berdasarkan hasil penelitian tersebut maka dapat disimpulkan bahwa nilai *size input* 224 dengan jumlah *epoch* 50 memiliki hasil yang paling optimal daripada kombinasi lainnya. Oleh karena itu penentuan nilai *size input* model dan penentuan jumlah *epoch* dapat mempengaruhi hasil kinerja suatu model.

### UCAPAN TERIMA KASIH

Ucapan terima kasih saya sampaikan kepada Tuhan Yang Maha Esa, Orang tua, teman-teman dan bapak ibu dosen yang telah mendukung serta membantu dalam menyelesaikan penelitian ini. Serta kepada LPPM Universitas Trunojoyo Madura sebagai mitra program riset ini.

## DAFTAR PUSTAKA

- [1] S. Anam Alidrus, M. Aziz, and O. Virgantara Putra, "Deteksi Penyakit Pada Daun Tanaman Padi Menggunakan Metode Convolutional Neural Network," *Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (SENAMIKA)*, pp. 103–109, 2021.
- [2] E. Maria, F. Fadlin, and M. Taruk, "Diagnosis Penyakit Tanaman Padi Menggunakan Metode Promethee," *Jurnal Ilmiah Komputer*, vol. 15, no. 1, Feb. 2020.
- [3] V. K. Gajjar, A. K. Nambisan, and K. L. Kosbar, "Plant Identification in a Combined-Imbalanced Leaf Dataset," *IEEE Access*, vol. 10, pp. 37882–37891, 2022.
- [4] S. Yuliany, Aradea, and A. Nur Rachman, "Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN)," *Jurnal Buana Informatika*, vol. 13, no. 1, pp. 54–65, 2022.
- [5] S. V. Darshan, "Automated Diagnosis and Cataloguing of Foliar Disease in Apple Trees using Ensemble of Deep Neural Networks," *International Research Journal of Engineering and Technology*, vol. 7, no. 05, pp. 4230–4237, 2020.
- [6] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," May 2019.
- [7] Ü. Atila, M. Uçar, K. Akyol, and E. Uçar, "Plant leaf disease classification using EfficientNet deep learning model," *Ecol Inform*, vol. 61, Mar. 2021.
- [8] V. Singh, A. Chug, and A. P. Singh, "Classification of Beans Leaf Diseases using Fine Tuned CNN Model," *Procedia Comput Sci*, vol. 218, pp. 348–356, 2023.
- [9] M. F. Martias, J. Jastril, S. Sanjaya, L. Handayani, and F. Yanto, "Klasifikasi Citra Daging Sapi dan Daging Babi Menggunakan CNN Arsitektur EfficientNet-B6 dan Augmentasi Data," *Jurnal Sistem Komputer dan Informatika (JSON)*, vol. 4, no. 4, pp. 642–653, Jun. 2023.
- [10] V. Susanti, S. Dwi Nurcahyanti, and D. R. Masnilah, "Perkembangan Penyakit dan Pertumbuhan Lima Varietas Padi (*Oryza sativa* L.) dengan Sistem Tanam Blok," *J. Agrotek. Trop*, vol. 7, no. 1, pp. 8–19, 2018.
- [11] A. Walascha *et al.*, "Inventarisasi Jenis Penyakit yang Menyerang Daun Tanaman Padi (*Oryza sativa* L.)," *Prosiding SEMNAS BIO 2021*, pp. 471–477, 2021.
- [12] S. Agustiani, Y. Tajul Arifin, A. Junaidi, S. Khotimatul Wildah, and A. Mustopa, "Klasifikasi Penyakit Daun Padi menggunakan Random Forest dan Color Histogram," *Jurnal Komputasi*, vol. 10, no. 1, pp. 65–74, 2022.
- [13] R. Permana, H. Saldu, and D. I. Maulana, "Optimasi Image Classification Pada Jenis Sampah Dengan Data Augmentation Dan Convolutional Neural Network," *Jurnal Sistem Informasi dan Informatika (Simika)*, vol. 5, no. 2, pp. 111–120, 2022.
- [14] I. K. Trisiawan, Y. Yuliza, and S. Attamimi, "Penerapan Multi-Label Image Classification Menggunakan Metode Convolutional Neural Network (CNN) Untuk Sortir Botol Minuman," *Jurnal Teknologi Elektro*, vol. 13, no. 1, p. 48, Feb. 2022.
- [15] E. Sentosa, D. Iskandar Mulyana, A. F. Cahyana, and N. G. Pramuditarsari, "Implementasi Image Classification Pada Batik Motif Bali Dengan Data Augmentation dan Convolutional Neural Network," *Jurnal Pendidikan Tambusai*, vol. 6, no. 1, pp. 1451–1463, 2022.
- [16] W. R. Perdani, R. Magdalena, and N. K. Caesar Pratiwi, "Deep Learning untuk Klasifikasi Glaukoma dengan menggunakan Arsitektur EfficientNet," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, no. 2, pp. 322–333, Apr. 2022.
- [17] J. Jiang *et al.*, "Evaluation of Diverse Convolutional Neural Networks and Training Strategies for Wheat Leaf Disease Identification with Field-Acquired Photographs," *Remote Sens (Basel)*, vol. 14, no. 14, Jul. 2022.
- [18] M. Farid Naufal and S. Ferdiana Kusuma, "Analisis Perbandingan Algoritma Machine Learning dan Deep Learning Untuk Klasifikasi Citra Sistem Isyarat Bahasa Indonesia (SIBI)," *Jurnal*



*Teknologi Informasi dan Ilmu Komputer*  
(*JTIK*), vol. 10, no. 4, pp. 873–882, 2023.