



Implementasi Arsitektur CNN untuk Klasifikasi dan Identifikasi Penyakit Daun Tanaman Padi

Helmy Purnomo Hidayat, Helmi Imaduddin*

Fakultas Komunikasi dan Informatika, Teknik Informatika, Universitas Muhammadiyah Surakarta, Surakarta
Jl. A. Yani, Mendungan, Pabelan, Kec. Kartasura, Kabupaten Sukoharjo, Jawa Tengah, Indonesia

Email: ¹helmypurnomo789@gmail.com, ^{2,*}hi776@ums.ac.id

Email Penulis Korespondensi: hi776@ums.ac.id

Submitted: 12/01/2026; Accepted: 28/01/2026; Published: 28/01/2026

Abstrak—Penyakit daun pada tanaman padi merupakan ancaman serius yang dapat menurunkan produktivitas dan mutu hasil panen, sehingga berdampak langsung terhadap ketahanan pangan nasional. Petani masih menghadapi berbagai kendala dalam mengidentifikasi penyakit secara konvensional, terutama pada fase awal infeksi yang berpotensi menyebabkan keterlambatan penanganan. Penelitian ini bertujuan mengembangkan sistem klasifikasi penyakit daun padi berbasis Deep Learning dengan membangun arsitektur Convolutional Neural Network (CNN) secara mandiri (from scratch). Dataset yang digunakan mencakup 18.445 citra daun padi yang terkategori ke dalam sepuluh kelas penyakit, dengan alokasi 70% data latih, 15% data validasi, dan 15% data uji. Seluruh citra diubah ukurannya menjadi 224×224 piksel sebelum dimasukkan ke model. Augmentasi data diterapkan untuk mencegah overfitting dengan rotasi (20°), pergeseran horizontal dan vertikal (15%), shear (15%), zoom (15%), horizontal flip, serta variasi brightness (0,8-1,2). Model CNN dirancang menggunakan lima blok konvolusi dengan konfigurasi filter bertingkat (32, 64, 128, 256, 512) menggunakan kernel 3×3 serta dilengkapi Batch Normalization, MaxPooling2D, dan Dropout. Model dikompilasi menggunakan optimizer Adam dengan learning rate 0.0001, fungsi loss categorical cross-entropy, dan fungsi aktivasi ReLU serta Softmax. Proses training menggunakan batch size 8 dilengkapi callback EarlyStopping dan ReduceLROnPlateau. Hasil eksperimen menunjukkan bahwa pelatihan dengan 75 epoch menghasilkan performa optimal dengan akurasi 97,91%, precision 0,9792, recall 0,9791, dan F1-score 0,9790 pada data uji. Evaluasi per kelas menunjukkan kelas Bacterial Leaf Blight dan Tungro mencapai akurasi sempurna (100%), sedangkan Leaf Blast memiliki akurasi terendah (93,8%) akibat kemiripan visual dengan Brown Spot. Model terbaik diimplementasikan ke dalam sistem web bernama Pariku menggunakan framework Flask, yang menyediakan fitur diagnosis otomatis, tingkat kepercayaan prediksi, serta rekomendasi penanganan berbasis Pengendalian Hama Terpadu (PHT).

Kata Kunci: Convolutional Neural Network (CNN); Deep Learning; Identifikasi Penyakit Tanaman; Klasifikasi Citra Digital; Penyakit Daun Padi; Sistem Deteksi.

Abstract—Leaf diseases in rice plants are a serious threat that can reduce productivity and crop quality, thus directly impacting national food security. Farmers still face various obstacles in identifying diseases conventionally, especially in the early stages of infection which can potentially cause delays in treatment. This study aims to develop a Deep Learning-based rice leaf disease classification system by building a Convolutional Neural Network (CNN) architecture independently (from scratch). The dataset used includes 18,445 rice leaf images categorized into ten disease classes, with an allocation of 70% training data, 15% validation data, and 15% test data. All images were resized to 224×224 pixels before being input into the model. Data augmentation was applied to prevent overfitting by rotation (20°), horizontal and vertical shifts (15%), shear (15%), zoom (15%), horizontal flip, and brightness variations (0.8-1.2). The CNN model was designed using five convolution blocks with cascaded filter configurations (32, 64, 128, 256, 512) using a 3×3 kernel and equipped with Batch Normalization, MaxPooling2D, and Dropout. The model was compiled using the Adam optimizer with a learning rate of 0.0001, a categorical cross-entropy loss function, and ReLU and Softmax activation functions. The training process used a batch size of 8 equipped with EarlyStopping and ReduceLROnPlateau callbacks. The experimental results showed that training with 75 epochs produced optimal performance with an accuracy of 97.91%, a precision of 0.9792, a recall of 0.9791, and an F1-score of 0.9790 on the test data. Evaluation per class showed that the Bacterial Leaf Blight and Tungro classes achieved perfect accuracy (100%), while Leaf Blast had the lowest accuracy (93.8%) due to its visual similarity to Brown Spot. The best model was implemented into a web system called Pariku using the Flask framework, which provides automatic diagnosis features, prediction confidence levels, and Integrated Pest Management (IPM)-based treatment recommendations.

Keywords: Convolutional Neural Network (CNN); Deep Learning; Plant Disease Identification; Digital Image Classification; Rice Leaf Disease; Detection System.

1. PENDAHULUAN

Padi (*Oryza sativa* L.) merupakan sumber makanan penting yang dibudidayakan secara luas di seluruh Indonesia dan memiliki peran penting dalam mendukung perkembangan ekonomi nasional [1]. Padi juga menjadi komponen utama ekosistem persawahan yang berperan sebagai sumber pangan bagi penduduk Indonesia mengingat statusnya sebagai penghasil karbohidrat utama selain gandum, jagung, dan berbagai jenis sereal [2]. Oleh karena itu, keberhasilan produksi padi memberikan pengaruh yang signifikan terhadap kerangka ketahanan pangan nasional [3]. Salah satu hambatan utama budidaya padi di Indonesia adalah timbulnya penyakit yang mempengaruhi dedaunan, yang secara signifikan dapat mengurangi produktivitas dan kualitas hasil panen. Tekanan biotik berupa infestasi organisme pengganggu dan infeksi patogen berkontribusi signifikan terhadap defisit produksi pangan, sekaligus mengancam keberlangsungan usaha tani [4]. Wabah pada vegetasi padi merupakan hambatan yang dihadapi oleh para pembudidaya setelah periode penanaman [5].



Padi yang terkena penyakit akan menampilkan gejala berupa bercak dan pola pewarnaan yang spesifik [6]. Diperkirakan 26% dari kejadian gagal panen disebabkan oleh serangan infeksi penyakit pada bagian daun tanaman pertanian [7]. Sementara itu, International Rice Research Institute (IRRI) melaporkan bahwa para petani menghadapi kerugian panen padi hingga 37% yang dikaitkan dengan dampak merugikan dari infestasi hama dan wabah penyakit. [8]. Fenomena perubahan iklim juga berkontribusi terhadap meningkatnya frekuensi serangan hama dan patogen pada tanaman padi. Situasi ini berdampak negatif terhadap pertumbuhan tanaman padi dan mengakibatkan penurunan capaian produksi, mencakup aspek kualitas maupun kuantitas [9].

Kesalahan identifikasi penyakit pada tanaman padi masih kerap terjadi di kalangan petani. Hama dan penyakit pada tanaman padi kerap kali tidak teridentifikasi pada tahap awal oleh para petani, terutama petani skala kecil yang belum memiliki akses terhadap teknologi identifikasi terkini [10]. Para petani sering meminta masukan dari lingkungan lokal mereka untuk mengenali jenis penyakit dan metode penanganannya [11]. Kondisi ini menyebabkan keterlambatan dalam pengambilan tindakan pengendalian yang tepat, sehingga penyakit dapat menyebar lebih luas dan menurunkan produktivitas tanaman secara signifikan [12]. Selain itu, ketergantungan pada pengetahuan tradisional tanpa dukungan data ilmiah yang akurat sering kali menyebabkan penggunaan pestisida yang berlebihan dan tidak tepat sasaran, yang pada akhirnya dapat merusak kualitas tanah serta mengancam keberlanjutan lingkungan pertanian [13]. Keadaan tersebut semakin memperbesar tingkat permasalahan penyakit pada tanaman padi, yang pada akhirnya menjadi salah satu hambatan utama bagi petani setelah fase penanaman.


Kemajuan pesat dalam teknologi informasi dan komputasi, khususnya pada bidang Deep Learning, sebuah subcabang dari Machine Learning telah menghadirkan metodologi yang digunakan secara luas untuk mengotomatiskan proses ekstraksi fitur dalam pembelajaran mesin serta mengintegrasikannya dengan tugas klasifikasi [14]. Deteksi penyakit tanaman secara manual sering kali memerlukan kemampuan khusus dan membutuhkan waktu yang lama, sehingga kurang efektif apabila diimplementasikan dalam skala luas [15]. Oleh sebab itu, pengembangan sistem otomatis dengan tingkat ketelitian yang tinggi menjadi sangat diperlukan dalam proses identifikasi penyakit tanaman [16].

Convolutional Neural Network (CNN) merupakan paradigma komputasi visual yang mengadopsi prinsip kerja sistem penglihatan biologis untuk mengenali pola kompleks pada data berbasis piksel [17]. Penelitian ini bertujuan untuk mengidentifikasi berbagai kategori patogen yang mempengaruhi tanaman padi melalui penerapan pendekatan Deep Learning berbasis CNN yang memungkinkan sistem untuk mendeteksi dan mengidentifikasi penyakit daun padi berdasarkan corak, tekstur, dan pola visual pada citra daun. Klasifikasi mencakup sepuluh kategori dengan variasi gejala visual yang kompleks, meliputi daun sehat (Healthy) serta penyakit Bacterial Leaf Blight, Brown Spot, Leaf Blast, Leaf Scald, Narrow Brown Spot, Neck Blast, Rice Hispa, Sheath Blight, dan Tungro. Penelitian ini mengembangkan arsitektur CNN secara mandiri (from scratch) untuk mengeksplorasi desain arsitektur yang fleksibel dan disesuaikan dengan kompleksitas klasifikasi sepuluh kelas penyakit daun padi. Model CNN bekerja dengan mengekstraksi fitur penting dari gambar seperti warna, bentuk, dan bercak untuk membedakan daun sehat dan terinfeksi. Penelitian terdahulu seringkali mengadopsi pendekatan Machine Learning seperti K-Nearest Neighbor (KNN), Naive Bayes, dan Support Vector Machine (SVM). Pendekatan ini menuntut dilakukannya ekstraksi fitur secara manual dan memiliki keterbatasan dalam identifikasi pola rumit pada daun. Pengimplementasian metode Deep Learning dengan arsitektur CNN, mempunyai kemampuan dalam mengekstraksi fitur secara otomatis dan memproses data dalam analisis citra, serta dapat mencapai tingkat akurasi klasifikasi penyakit pada daun padi [18]. Beberapa penelitian sebelumnya telah mengkaji klasifikasi penyakit daun padi menggunakan CNN, di antaranya [19] menggunakan dataset berjumlah 6.000 citra, namun penelitian tersebut hanya berfokus pada klasifikasi tiga jenis penyakit daun padi dengan akurasi 98% pada pelatihan 100 epoch. [10] menerapkan CNN untuk diagnosis penyakit daun padi berbasis citra digital dengan fokus pada tiga kelas penyakit, namun penelitian tersebut masih menggunakan dataset sebanyak 240 citra sehingga generalisasi model kurang optimal. Penelitian lain oleh [7] memperoleh akurasi 97,75% dengan teknik optimasi augmentasi pada 480 citra uji untuk empat kelas penyakit. Berbeda penelitian yang dilakukan oleh [6] menggunakan metode ekstraksi fitur GLCM dan algoritma KNN yang menghasilkan akurasi maksimal hanya 73%. Oleh karena itu, penelitian ini berkontribusi mengembangkan arsitektur CNN from scratch dengan lima blok konvolusi dengan akurasi tertinggi sebesar 97,91% pada data uji. Dengan data sepuluh kelas penyakit menganalisis pengaruh variasi epoch (25, 50, 75, 100) terhadap performa. Dengan menggunakan 18.445 citra dengan augmentasi komprehensif dan mengimplementasikan model ke sistem pariku.web.id dengan rekomendasi penanganan berbasis PHT.

2. METODOLOGI PENELITIAN

Metodologi penelitian ini disusun secara terstruktur agar model dapat menghasilkan prediksi yang presisi terhadap data masukan berupa citra. Penelitian ini bertumpu pada pemanfaatan algoritma CNN karena dinilai memiliki kemampuan yang baik dan menunjukkan performa superior dalam pengolahan dataset visual [20]. CNN digunakan untuk menganalisis pola dan fitur sebagai penanda kondisi tanaman. Pendekatan ini mengandalkan serangkaian lapisan konvolusi untuk mengekstraksi karakteristik penting dari citra, yang selanjutnya dimanfaatkan sebagai dasar dalam proses klasifikasi berdasarkan pola visual yang berhasil diidentifikasi [21]. Penelitian ini menguraikan

serangkaian langkah yang telah dilaksanakan guna mengkategorikan berbagai jenis penyakit yang menyerang daun tanaman padi, Pada Gambar 1. sebagai berikut:










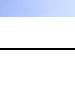


Gambar 1. Tahapan Penelitian

2.1 Pengumpulan Data

Dataset yang digunakan berupa kumpulan citra daun padi yang diperoleh dari platform Kaggle dan dimanfaatkan dalam proses identifikasi serta klasifikasi penyakit daun padi. Dalam penelitian ini, digunakan dataset Rice_Leaf_Disease yang berasal dari dataset rice-leaf-diseases-detection yang berisi 10 kelas citra daun. Secara keseluruhan, dataset terdiri atas 18.445 citra daun padi yang merepresentasikan variasi penyakit daun padi. Tabel 1. Dataset yang menunjukkan contoh dan jumlah gambar yang dipergunakan pada penelitian ini

Tabel 1. Dataset

Kelas	Gambar	Jumlah Dataset
Bacterial Leaf Blight		1.762
Brown Spot		1.860
Healthy		1.882
Leaf Blast		2.163
Leaf Scald		2.056
Narrow Brown Spot		1.798
Neck Blast		1.322
Rice Hispa		1.686
Sheath Blight		1.866
Tungro		2.050
Total		18.445

2.2 Preprocessing Data

Tahap preprocessing data bertujuan untuk memastikan data citra memiliki format dan karakteristik yang seragam agar dapat diolah dengan optimal oleh model CNN [22]. Pembagian dataset citra daun padi menjadi tiga bagian menggunakan metode data splitting. Dataset yang digunakan, yaitu Rice_Leaf_Disease, dibagi menjadi 70% data latih, 15% data validasi dan 15% data, menghasilkan 12.903 citra untuk data latih, 2.771 citra untuk data validasi, dan 2.771 citra untuk data uji dengan menggunakan fungsi `train_test_split` serta nilai `random state` sebesar 42 untuk menjaga konsistensi dan reproduibilitas hasil eksperimen. Ketidakeimbangan jumlah sampel antar kelas diatasi dengan menerapkan teknik `class weighting`, di mana kelas dengan jumlah sampel lebih sedikit diberikan bobot lebih tinggi.

Selanjutnya, diterapkan proses augmentasi citra pada data latih dengan menggunakan kelas `ImageDataGenerator`, yang berfungsi untuk memperluas variasi data secara artifisial tanpa menambah data baru

secara manual. Seluruh citra diseragamkan ukurannya menjadi resolusi 224×224 piksel agar sesuai dengan spesifikasi dimensi masukan pada model CNN, kemudian dinormalisasi ke dalam rentang nilai $[0,1]$ Proses normalisasi ini dilakukan untuk mempercepat konvergensi model selama pelatihan, mengurangi perbedaan skala antar fitur, serta memastikan stabilitas hasil prediksi. dengan membagi setiap nilai piksel dengan 255. Parameter augmentasi yang digunakan meliputi rotasi (20°), pergeseran horizontal dan vertikal (15%), shear (15%), zoom (15%), horizontal flip, serta variasi brightness (0,8-1,2). Tujuan dari penerapan augmentasi ini adalah untuk meningkatkan keberagaman citra pelatihan serta mencegah terjadinya overfitting, sehingga model dapat belajar dengan lebih baik terhadap pola-pola yang bervariasi. Dengan demikian, seluruh data citra yang telah melalui tahapan preprocessing siap digunakan dalam proses pelatihan, validasi, dan pengujian model klasifikasi penyakit daun padi.

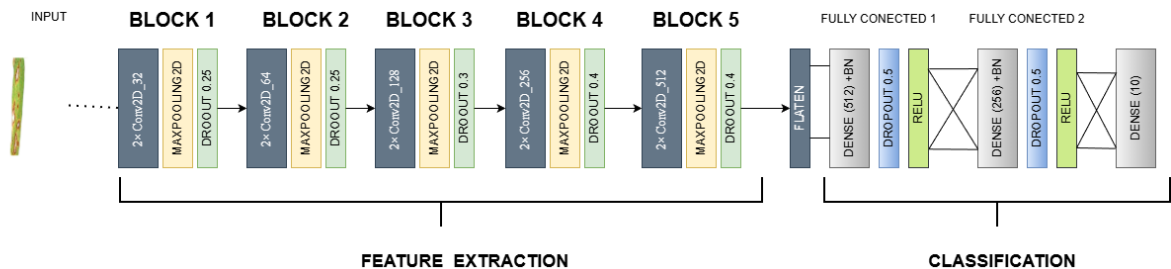
2.3 Pembuatan Model CNN

Setelah data melalui tahap preprocessing selesai, langkah selanjutnya adalah perancangan arsitektur CNN. Arsitektur yang dirancang terdiri atas beberapa lapisan utama, yaitu Feature Extraction dan Fully Connected (Classification). Feature Extraction adalah lapisan yang menangkap pola visual dari gambar tepi, tekstur, dan bentuk pada daun padi. Feature Extraction Meliputi lapisan konvolusi (Conv2D) mengekstraksi fitur penting seperti tepi, sudut, tekstur, dan bentuk dari citra daun padi, lapisan pooling (MaxPooling2D) digunakan untuk mereduksi ukuran dimensi ekstraksi fitur dengan tetap mempertahankan informasi penting dari citra.

Fully Connected (Classification) berfungsi untuk mengambil fitur hasil ekstraksi dan mengubahnya jadi keputusan prediksi kelas. Meliputi lapisan Flatten untuk mengubah data dua dimensi menjadi satu dimensi agar dapat diproses oleh lapisan Dense, serta lapisan Dense berfungsi untuk melakukan proses pembobotan terhadap seluruh neuron dan menggabungkan informasi dari setiap fitur yang diperoleh sebelumnya. Aktivasi ReLU digunakan untuk menambahkan non-linearitas dengan mengubah nilai negatif menjadi nol dan Softmax lapisan keluaran mengubah hasil model menjadi probabilitas tiap kelas sehingga citra dapat diklasifikasikan ke dalam kelas yang sesuai.

Model CNN ini diimplementasikan menggunakan framework TensorFlow sebagai alat bantu pengembangan dan pelatihan model. Arsitektur yang digunakan terdiri atas lima blok konvolusi, sebagai Feature Extraction layer dengan jumlah filter yang meningkat secara bertahap (32, 64, 128, 256, 512), kernel 3×3 digunakan untuk mendeteksi fitur visual, padding same menjaga ukuran dimensi output tetap sama dengan input, Batch Normalization untuk menstabilkan proses pembelajaran, MaxPooling2D (2×2) untuk mereduksi dimensi spasial, dan Dropout untuk mencegah overfitting. Lapisan classification terdiri atas dua lapisan fully connected dengan aktivasi ReLU dan Softmax. Model dikompilasi dengan menerapkan optimizer Adam dengan learning rate 0,0001 serta menggunakan categorical cross-entropy sebagai fungsi loss.

Penentuan nilai hyperparameter seperti jumlah filter, ukuran kernel, dropout rate, dan learning rate dilakukan menggunakan data validasi. Data validasi digunakan untuk menilai performa setiap konfigurasi model dan memilih kombinasi parameter yang memberikan hasil terbaik sebelum dilakukan pengujian akhir menggunakan data uji. Selain itu, untuk memperoleh performa model yang optimal, penelitian ini juga melakukan perbandingan terhadap variasi jumlah epoch, yaitu 25, 50, 75, dan 100 epoch. Perbandingan ini bertujuan untuk menganalisis pengaruh jumlah epoch terhadap kompleksitas pelatihan model, serta dampaknya terhadap akurasi dan stabilitas model dalam proses klasifikasi citra. Arsitektur CNN yang digunakan pada Gambar 2. sebagai berikut:



Gambar 2. Arsitektur CNN

2.4 Evaluasi Hasil Prediksi dan Pengujian Model

Tahap evaluasi ini bertujuan untuk menilai tingkat kinerja serta kemampuan generalisasi model dalam melakukan klasifikasi citra [23]. Evaluasi dilakukan dengan menggunakan data test yang terpisah dari data pelatihan, sehingga hasil pengujian dapat menggambarkan kapasitas model untuk mengidentifikasi pola visual yang sebelumnya tidak ditemui. Pada tahap evaluasi, prediksi yang dihasilkan oleh model dibandingkan gambar label sebenarnya (ground truth) yang melekat pada setiap gambar dalam dataset. Perbandingan ini digunakan untuk menghitung berbagai metrik evaluasi, antara lain akurasi (accuracy), presisi (precision), recall, dan F1-score. Accuracy merepresentasikan rasio prediksi yang tepat terhadap keseluruhan sampel uji [24]. Precision menghitung persentase kebenaran dari seluruh data yang diprediksi positif. Recall menilai sejauh mana model berhasil

mengidentifikasi contoh positif dalam kumpulan data. F1-Score merupakan rata-rata harmonik antara precision dan recall, yang berfungsi sebagai indikator keseimbangan kedua metrik tersebut [25]. Secara matematis, metrik evaluasi tersebut dapat dituliskan dengan persamaan sebagai berikut:

$$\text{Accuracy} = \frac{\sum_{i=1}^k TP_i}{N} \tag{1}$$

$$\text{Precision}_i = \frac{TP_i}{TP_i + FP_i} \tag{2}$$

$$\text{Recall}_i = \frac{TP_i}{TP_i + FN_i} \tag{3}$$

$$F1_i = 2 \times \frac{\text{Precision}_i \times \text{Recall}_i}{\text{Precision}_i + \text{Recall}_i} \tag{4}$$

Notasi yang digunakan dalam perhitungan metrik evaluasi meliputi *i* sebagai indeks kelas ke-*i*, *TP_i* (True Positive) merupakan jumlah data kelas ke-*i* yang diprediksi benar, *FP_i* (False Positive) adalah jumlah data yang salah diprediksi sebagai kelas ke-*i*, *FN_i* (False Negative) menunjukkan jumlah data kelas ke-*i* yang tidak terdeteksi, *k* adalah jumlah kelas dimana dalam penelitian ini *k* = 10, dan *N* merupakan total jumlah data uji. Evaluasi ini berfungsi sebagai dasar dalam menentukan sejauh mana model mampu melakukan klasifikasi citra daun padi secara tepat dan konsisten.

2.5 Deployment

Tahap deployment merupakan proses penerapan model CNN terbaik ke dalam sistem berbasis antarmuka pengguna yang interaktif. Sistem ini dirancang sebagai dashboard sederhana dengan fitur unggah citra daun padi sebagai input dan hasil keluaran berupa identifikasi kelas penyakit serta tingkat akurasi prediksi. Antarmuka pengguna dikembangkan menggunakan framework Flask, yang memfasilitasi pengembangan aplikasi web secara efisien dan ringan [26]. Sistem diberi nama Pariku.web.id. Tahap ini bertujuan untuk menjadikan model yang telah dikembangkan dapat digunakan secara praktis dalam membantu proses deteksi penyakit daun padi secara tepat dan efisien.

3. HASIL DAN PEMBAHASAN

Penelitian ini menghasilkan model klasifikasi penyakit daun padi menggunakan arsitektur CNN yang dirancang dari awal (from scratch). Model dilatih menggunakan dataset total 18.445 citra daun padi yang terbagi ke dalam sepuluh kelas, menjadi 70% data latih, 15% data validasi dan 15% data, menghasilkan 12.903 citra untuk data latih, 2.771 citra untuk data validasi, dan 2.771. yaitu berisi kelas Bacterial Leaf Blight, Brown Spot, Healthy, Leaf Blast, Leaf Scald, Narrow Brown Spot, Neck Blast, Rice Hispa, Sheath Blight, dan Tungro. Eksperimen dilakukan dengan empat konfigurasi variasi epoch untuk menemukan konfigurasi optimal.

3.1 Arsitektur Model CNN

Arsitektur CNN yang digunakan dalam penelitian ini terdiri atas lima blok konvolusi yang berfungsi sebagai Feature Extraction layer dan lapisan fully connected yang berfungsi sebagai classification layer. Setiap blok konvolusi terdiri atas lapisan Conv2D, Batch Normalization, dan MaxPooling2D yang dilengkapi dengan Dropout untuk mencegah overfitting. Konfigurasi arsitektur model CNN disajikan pada Tabel 2.

Tabel 2. Arsitektur Model CNN 5 Block

Blok	Komponen	Output Shape	Keterangan
Block 1	2× Conv2D (32 filters) + BN + ReLU + MaxPooling + Dropout	(112, 112, 32)	KERNEL 3×3, POOL 2×2, DROPOUT 0.25
Block 2	2× Conv2D (64 filters) + BN + ReLU + MaxPooling + Dropout	(56, 56, 64)	KERNEL 3×3, POOL 2×2, DROPOUT 0.25
Block 3	2× Conv2D (128 filters) + BN + ReLU + MaxPooling + Dropout	(28, 28, 128)	KERNEL 3×3, POOL 2×2, DROPOUT 0.3
Block 4	2× Conv2D (256 filters) + BN + ReLU + MaxPooling + Dropout	(14, 14, 256)	KERNEL 3×3, POOL 2×2, DROPOUT 0.4
Block 5	1× Conv2D (512 filters) + BN + ReLU + MaxPooling + Dropout	(7, 7, 512)	KERNEL 3×3, POOL 2×2, DROPOUT 0.4
Flatten	Flatten	(25088)	KONVERSI 2D KE 1D
Fully Connected 1	Dense (512) + BN+ ReLU + Dropout 0.5	(512)	FULLY CONNECTED LAYER
Fully Connected 2	Dense (256) + BN+ReLU+ Dropout 0.5	(256)	FULLY CONNECTED LAYER
Output	Dense (10) + Softmax	(10)	KLASIFIKASI, 10 KELAS

Berdasarkan arsitektur yang dirancang, total parameter dalam model ini sebanyak 15.340.842 parameter, terdiri atas 15.336.362 parameter trainable dan 4.480 parameter non-trainable. Parameter non-trainable berasal dari nilai mean dan variance pada layer Batch Normalization. Model dikompilasi memanfaatkan optimizer Adam dengan learning rate sebesar 0,0001 dan loss function categorical crossentropy. Proses pelatihan diterapkan dengan 75 epoch yang dilengkapi dengan callback EarlyStopping untuk menghentikan pelatihan Apabila tidak ada peningkatan performa, dan ReduceLRonPlateau untuk menurunkan learning rate dengan cara adaptif.

3.2 Hasil Pelatihan Model

Eksperimen dilakukan dengan empat konfigurasi berbeda untuk menganalisis pengaruh jumlah epoch terhadap performa model. Hasil perbandingan performa model pada setiap konfigurasi disajikan pada Tabel 3.

Tabel 3. Perbandingan Performa Model dengan Variasi Epoch.

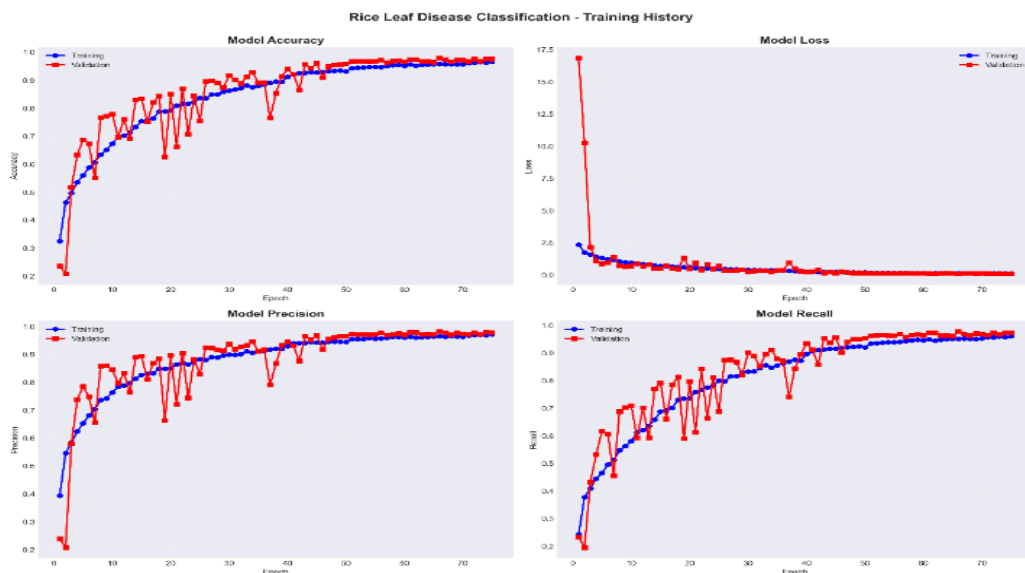
Model	Train Accuracy	Val Accuracy	Test Accuracy
25 Epoch	89,97%	88,44%	89,93%
50 Epoch	97,80%	96,57%	97,37%
75 Epoch	98,76%	97,58%	97,91%
100 Epoch	97,08%	96,17%	96,43%

Berdasarkan Tabel 3 model dengan konfigurasi 75 epoch. Menunjukkan performa terbaik dengan akurasi data uji tertinggi sebesar 97,91%. Hasil eksperimen menunjukkan pola yang jelas mengenai pengaruh jumlah epoch terhadap performa model. Model menggunakan data test dengan 25 epoch hanya mencapai akurasi 89,93%, yang mengindikasikan bahwa model belum cukup belajar (underfitting). Peningkatan epoch ke 50 memberikan lonjakan signifikan ke 97,37%, kemudian mencapai puncak pada 75 epoch dengan 97,91%.

Analisis lebih lanjut menunjukkan bahwa peningkatan epoch dari 25 ke 50 memberikan peningkatan akurasi sebesar 7,44%, dari 50 ke 75 epoch meningkat 0,54%, namun dari 75 ke 100 epoch justru mengalami penurunan sebesar 1,48%. Fenomena ini mengindikasikan adanya titik optimal pada sekitar 75 epoch, dimana pelatihan yang terlalu singkat menyebabkan underfitting dan pelatihan yang terlalu lama menyebabkan overfitting.

3.3 Evaluasi Model Terbaik

Visualisasi proses pelatihan model terbaik 75 epoch yang menunjukkan perkembangan akurasi, loss, precision, dan recall selama proses training disajikan pada Gambar 3.



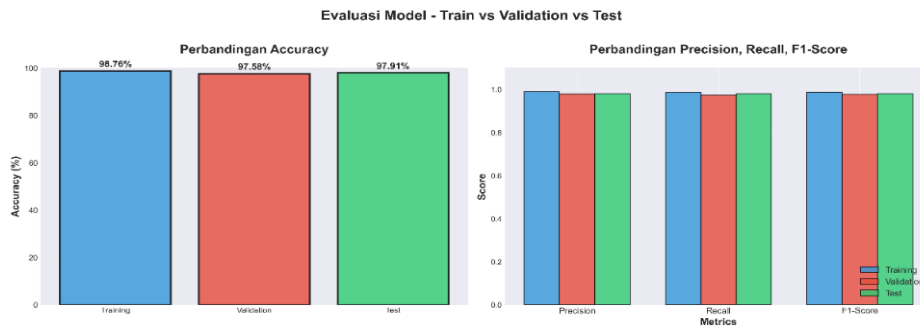
Gambar 3. Visualisasi Training History Model CNN Terbaik 75 epoch.

Berdasarkan Gambar 3 proses pelatihan model menunjukkan kinerja yang stabil dan efisien. Kurva akurasi pada data pelatihan dan validasi mengalami peningkatan secara konsisten sejak epoch awal hingga mencapai kondisi konvergensi. Sementara itu, nilai loss pada kedua dataset tersebut menunjukkan tren penurunan yang signifikan. Fluktuasi yang terlihat pada kurva disebabkan oleh penggunaan batch size 8 yang relatif kecil serta penerapan augmentasi data secara real-time, namun secara keseluruhan model tetap konvergen dengan stabil. Perbedaan yang relatif kecil antara kurva pelatihan dan validasi pada metrik accuracy, loss, precision, dan recall menunjukkan bahwa model tersebut tidak overfitting dan memiliki kemampuan generalisasi yang baik. Evaluasi performa model terbaik selanjutnya dilakukan menggunakan tiga dataset, yaitu data latih, data validasi, dan data uji. Hasil evaluasi performa model terbaik pada masing-masing dataset disajikan pada Tabel 4 berikut.

Tabel 4. Hasil evaluasi performa model terbaik

Metrik	Data latih	Data validasi	Data uji
Accuracy	98,76%	97,58%	97,91%
Precision	0,9900	0,9789	0,9792
Recall	0,9860	0,9736	0,9791
F1-Score	0,9880	0,9763	0,9790
Loss	0,0394	0,0851	0,0692

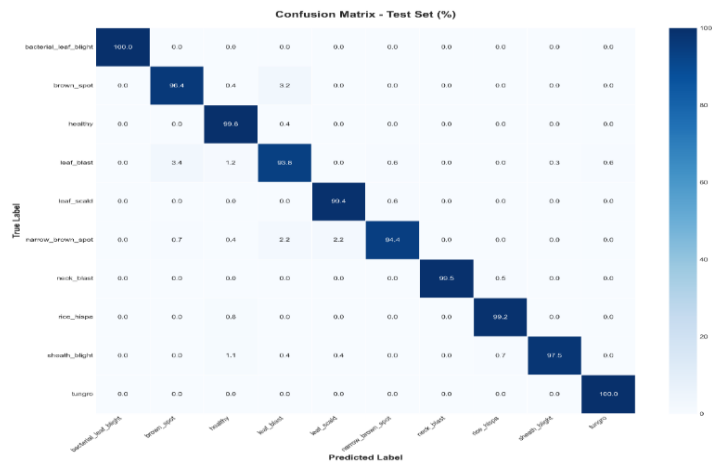
Berdasarkan Tabel 4 hasil evaluasi performa model terbaik menunjukkan kinerja yang sangat baik dan konsisten pada ketiga dataset yang digunakan. Evaluasi performa model pada data latih dan validasi dilakukan menggunakan fungsi `model.evaluate()`. Pada data uji, nilai loss diperoleh menggunakan fungsi `model.evaluate()`, sedangkan metrik accuracy, precision, recall, dan F1-score dihitung berdasarkan confusion matrix menggunakan library Scikit-learn. Nilai akurasi pada data test sebesar 97,91% bahkan sedikit lebih tinggi dibandingkan dengan data validasi yang mencapai 97,58%, sehingga mencerminkan kemampuan generalisasi model yang baik. Selain itu, nilai precision, recall, dan F1-score yang tinggi serta relatif seimbang menunjukkan bahwa model mampu melakukan klasifikasi secara optimal tanpa menunjukkan kecenderungan bias terhadap kelas tertentu. Visualisasi perbandingan metrik evaluasi model ditampilkan pada Gambar 4.



Gambar 4. Visualisasi Perbandingan Evaluasi Model pada Training, Validation, dan Test Set

3.4 Evaluasi Klasifikasi Per Kelas

Evaluasi Klasifikasi Per Kelas dilakukan dengan menggunakan confusion matrix untuk mengetahui performa model dalam mengklasifikasikan setiap kelas penyakit daun padi. Confusion matrix hasil prediksi model pada data uji disajikan pada Gambar 5.



Gambar 5. Confusion matrix pada data uji.

Berdasarkan confusion matrix pada data test yang ditunjukkan pada Gambar 5. dapat diamati bahwa model mampu mengklasifikasikan sebagian besar kelas dengan tingkat akurasi yang sangat tinggi. Kelas Bacterial Leaf Blight dan Tungro mencapai tingkat klasifikasi sempurna sebesar 100%, sedangkan kelas Neck Blast, Rice Hispa, dan Leaf Scald masing-masing menunjukkan akurasi di atas 99%. Adapun kelas Leaf Blast memiliki akurasi terendah sebesar 93,8%, di mana sebagian sampelnya masih salah diklasifikasikan sebagai Brown Spot sebesar 3,4% dan sebagai Healthy sebesar 1,2%. Kesalahan klasifikasi tersebut diduga dipengaruhi oleh adanya tumpang tindih karakteristik visual, khususnya pola bercak dan perubahan warna daun, yang menyerupai gejala Brown Spot maupun kondisi daun sehat pada tahap awal perkembangan penyakit. Secara keseluruhan, hasil confusion matrix menunjukkan bahwa kesalahan klasifikasi relatif kecil dan hanya terdistribusi pada beberapa kelas tertentu, yang

mengindikasikan performa model yang stabil dan andal. Detail performa klasifikasi untuk setiap kelas disajikan pada tabel 5. berikut.

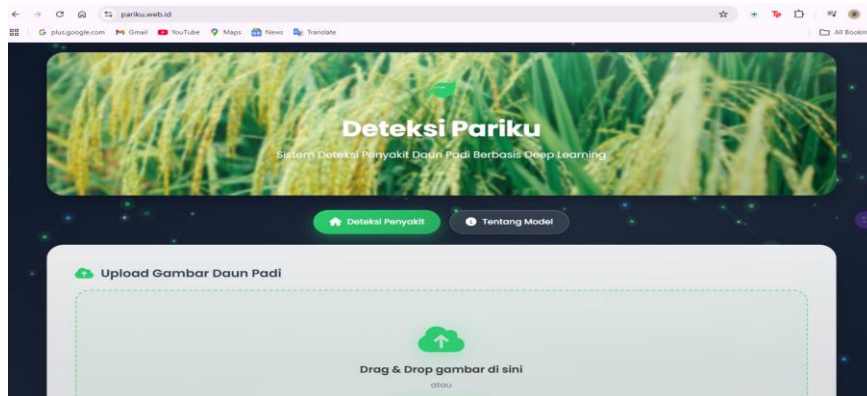
Tabel 5. Classification Report Per Kelas Model Terbaik.

Kelas	Precision	Recall	F1-Score	Support
Bacterial Leaf Blight	1,0000	1,0000	1,0000	265
Brown Spot	0,9539	0,9642	0,9590	279
Healthy	0,9625	0,9965	0,9792	283
Leaf Blast	0,9472	0,9385	0,9428	325
Leaf Scald	0,9777	0,9935	0,9856	309
Narrow Brown Spot	0,9846	0,9444	0,9641	270
Neck Blast	1,0000	0,9950	0,9975	199
Rice Hispa	0,9882	0,9921	0,9901	253
Sheath Blight	0,9964	0,9750	0,9856	280
Tungro	0,9935	1,0000	0,9968	308
Macro Average	0,9804	0,9799	0,9801	2771
Weighted Average	0,9792	0,9791	0,9790	2771

Berdasarkan Tabel 5 dapat dilihat bahwa semua kelas memiliki nilai precision, recall, dan F1-Score di atas 0,93. Kelas Bacterial Leaf Blight mencapai performa sempurna dengan nilai 1,0000 pada semua metrik. Kelas Leaf Blast memiliki performa terendah namun masih sangat baik dengan F1-Score 0,9428. Macro average menunjukkan nilai precision 0,9804, recall 0,9799, dan F1-Score 0,9801 yang mengindikasikan performa model yang sangat baik dan seimbang di seluruh kelas.

3.5 Implementasi Sistem Deteksi

Model CNN terbaik dengan konfigurasi 75 epoch dengan accuracy 97,91% menggunakan dataset test diimplementasikan ke dalam sistem berbasis web menggunakan Flask. Sistem ini diberi nama Pariku. Sistem menyediakan antarmuka pengguna yang interaktif dengan fitur unggah gambar daun padi dan menampilkan hasil diagnosis berupa jenis penyakit, tingkat keyakinan (confidence), serta rekomendasi penanganan yang sesuai untuk membantu petani dalam mengambil keputusan pengendalian penyakit.



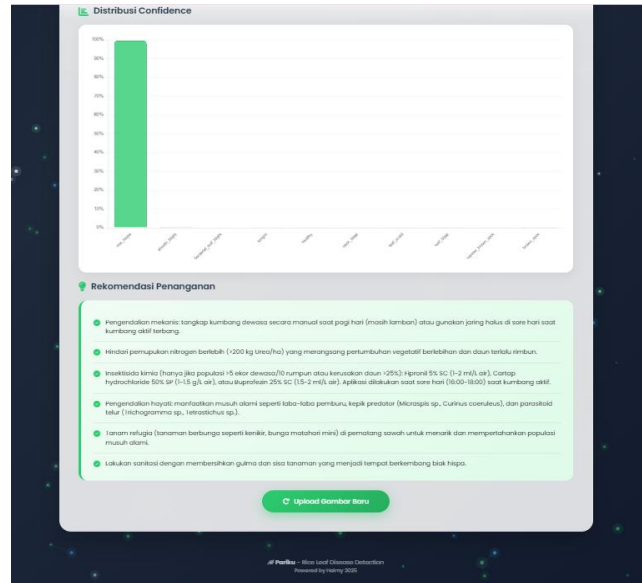
Gambar 6. Tampilan ui upload pada aplikasi.

Pada Gambar 6 menampilkan antarmuka sistem deteksi penyakit daun padi yang menyediakan fitur unggah citra sebagai masukan model. Pengguna dapat mengunggah citra daun padi yang selanjutnya diproses melalui tahap praproses, termasuk penyesuaian ukuran citra menjadi 224 × 224 piksel sesuai dengan kebutuhan arsitektur model CNN. Citra hasil praproses tersebut kemudian digunakan sebagai input untuk melakukan prediksi kelas penyakit daun padi secara otomatis.



Gambar 7. Tampilan contoh hasil prediksi setelah file diupload.

Gambar 7 menampilkan contoh hasil diagnosis sistem deteksi penyakit daun padi. Bagian kiri menunjukkan citra masukan, sedangkan bagian kanan menampilkan contoh hasil prediksi berupa kelas Rice Hispa dengan tingkat kepercayaan. Sistem juga menyajikan deskripsi karakteristik hama serta tiga prediksi teratas beserta probabilitasnya, sehingga pengguna dapat memahami tingkat kepastian prediksi dan mempertimbangkan kelas alternatif dalam pengambilan keputusan penanganan penyakit padi.



Gambar 8. Tampilan contoh hasil diagnosis dan rekomendasi penanganan.

Pada Gambar 8 menampilkan contoh hasil diagnosis penanganan dan probabilitas persentase keyakinan (confidence) melalui grafik tabel. Sistem juga menyajikan rekomendasi penanganan berbasis Pengendalian Hama Terpadu (PHT) meliputi pengendalian mekanis, pengelolaan pemupukan, penggunaan insektisida selektif, pengendalian hayati, penanaman refugia, dan sanitasi lahan untuk mendukung pengambilan keputusan pengguna dalam mengatasi masalah penyakit daun.

3.6 Pembahasan

Meninjau penelitian sebelumnya, model CNN yang dikembangkan dalam penelitian ini memiliki keunggulan dari sisi cakupan klasifikasi dan kinerja model. Studi oleh [19] melaporkan akurasi sebesar 98% pada pelatihan selama 100 epoch menggunakan dataset berjumlah 6.000 citra, namun penelitian tersebut hanya berfokus pada klasifikasi tiga jenis penyakit daun padi. Sementara itu, [7] memperoleh akurasi 97,75% dengan teknik optimasi augmentasi pada 480 citra uji untuk empat kelas penyakit. Penelitian lain oleh [10] mencapai akurasi validasi 91,67% dan testing 92% pada 100 epoch dengan dataset 240 citra untuk tiga kelas.

Berbeda dengan pendekatan-pendekatan tersebut, [6] menggunakan metode ekstraksi fitur GLCM dan algoritma KNN yang menghasilkan akurasi maksimal hanya 73%. Penelitian ini memberikan kontribusi signifikan dengan mengklasifikasikan sepuluh kelas penyakit daun padi secara simultan menggunakan dataset yang lebih besar (18.445 citra), arsitektur CNN yang lebih kompleks dengan lima blok konvolusi, serta implementasi sistem berbasis web bernama Pariku menggunakan Flask yang menyediakan antarmuka interaktif dengan fitur unggah citra, hasil diagnosis otomatis beserta tingkat kepercayaan (confidence score), dan rekomendasi penanganan berbasis prinsip Pengendalian Hama Terpadu (PHT). Selain keunggulan akurasi, efisiensi komputasi dioptimalkan dengan mengonversi model .keras menjadi TensorFlow Lite (.tflite). Strategi ini mereduksi latensi inferensi secara signifikan, memungkinkan sistem pariku.web.id memproses prediksi secara near real-time, sehingga petani mendapatkan diagnosis instan tanpa terbebani kompleksitas komputasi.

4.KESIMPULAN

Penelitian ini telah berhasil mengembangkan sistem klasifikasi penyakit daun padi berbasis CNN yang dirancang dari awal (from scratch) dengan arsitektur lima blok konvolusi menggunakan konfigurasi filter progresif (32, 64, 128, 256, 512), Batch Normalization, MaxPooling2D, dan Dropout. Model dilatih menggunakan dataset sebanyak 18.445 citra daun padi yang terbagi ke dalam sepuluh kelas penyakit dengan pembagian 70% data latih, 15% data validasi, dan 15% data uji. Hasil eksperimen menunjukkan bahwa konfigurasi pelatihan dengan 75 epoch menghasilkan performa optimal dengan akurasi tertinggi sebesar 97,91% pada data uji, disertai nilai precision 0,9792, recall 0,9791, dan F1-score 0,9790 yang mengindikasikan kemampuan generalisasi model yang sangat baik tanpa bias terhadap kelas tertentu. Evaluasi per kelas menunjukkan bahwa kelas Bacterial Leaf Blight dan Tungro mencapai akurasi klasifikasi sempurna (100%), sedangkan kelas Leaf Blast memiliki akurasi terendah



sebesar 93,8% yang disebabkan oleh kemiripan karakteristik visual dengan kelas Brown Spot dan Healthy pada tahap awal perkembangan penyakit. Penelitian selanjutnya dapat difokuskan pada Pengembangan arsitektur yang lebih ringan seperti MobileNet atau EfficientNet untuk deployment pada perangkat mobile dengan sumber daya terbatas. Perluasan dataset dengan menambahkan varietas padi lokal Indonesia dan kondisi pencahayaan yang lebih beragam. Integrasi dengan sistem IoT untuk pemantauan real-time di lahan pertanian.

REFERENCES

- [1] Dewi Pitriana, Hery Haryanto, and Kisman, “Evaluasi Penerapan Pengendalian Hama Terpadu Petani Padi (*Oryza sativa*) dalam Program P4 di Kabupaten Lombok Barat,” *J. Ilm. Mhs. Agrokomplek*, vol. 4, no. 1, pp. 146–154, Apr. 2025, doi: 10.29303/jima.v4i1.6587.
- [2] T. H. Masitah, S. Y. Lubis, and R. Harahap, “Analisis Faktor Sosial Dan Ekonomi Yang Mempengaruhi Pendapatan Petani Padi Organik,” *J. Ilman J. Ilmu Manaj.*, vol. 11, no. 3, pp. 8–15, Oct. 2023, doi: 10.35126/ilman.v11i3.532.
- [3] M. Yustika and E. Marbun, “Pelestarian plasma nutfah padi untuk mendukung ketahanan pangan beras Indonesia,” *J. Crit. Ecol.*, vol. 1, no. 2, pp. 52–59, 2024, doi: <https://doi.org/10.61511/jereco.v1i2.1170>.
- [4] Z. He, Z. Zhang, G. Valè, B. S. Segundo, X. Chen, and J. Pasupuleti, “Editorial : Disease and pest resistance in rice,” *Front. Plant Sci.*, vol. 14, no. 1, pp. 1–3, 2023, doi: 10.3389/fpls.2023.1333904.
- [5] M. Deden, M. Fauzi, T. Al Mudzakir, C. E. Sukmawati, and J. Indra, “Deteksi Jenis Penyakit Pada Tanaman Padi Menggunakan Yolo V5,” *KLIK Kaji. Ilm. Inform. dan Komput.*, vol. 5, no. 1, pp. 39–48, 2024, doi: 10.30865/klik.v5i1.2009.
- [6] D. Wahyudi, F. Liantoni, N. Pradana, and T. Prakisya, “Identifikasi Penyakit Daun pada Tanaman Padi Menggunakan Ekstraksi Fitur Gray Level Co-occurrence Matrix (GLCM) dan Metode K-Nearest Neighbour (KNN),” *J. Sist. dan Teknol. Inf.*, vol. 12, no. 1, pp. 100–106, 2024, doi: 10.26418/justin.v12i1.69752.
- [7] P. Novantara, R. L. Firmansyah, and Marrison Arismawati, “Deteksi Hama Penyakit Daun Padi Dengan Menggunakan Teknik Optimasi Deep Learning Convolutional Neural Network,” *bit-Tech*, vol. 7, no. 3, pp. 975–983, Apr. 2025, doi: 10.32877/bt.v7i3.2284.
- [8] H. N. Niko Pirnando, J. Petrus, and T. Tinaliah, “Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network dengan Arsitektur AlexNet,” *MDP Student Conf.*, vol. 4, no. 1, pp. 207–214, Apr. 2025, doi: 10.35957/mdp-sc.v4i1.11099.
- [9] W. Wagiyanti, H. Hamidson, and S. Suwandi, “Intensity and Incidence of Pest Disease Attacks on Rice Plants in Enggal Rejo Village, Air Salek Subdistrict,” *J. Glob. Sustain. Agric.*, vol. 4, no. 2, p. 144, Jun. 2024, doi: 10.32502/jgsa.v4i2.8408.
- [10] I. Irawan, M. H. Wathan, B. Swengky, and A. Ramadani, “Implementasi Convolutional Neural Network (CNN) dalam Diagnosa Penyakit Daun Padi Berdasarkan Citra Digital,” *J. Pengemb. Sist. Inf. dan Inform.*, vol. 6, no. 3, pp. 55–67, Jul. 2025, doi: 10.47747/jpsii.v6i3.2756.
- [11] E. King et al., “Engaging the agricultural community in the development of mental health interventions: a qualitative research study,” *BMC Psychiatry*, vol. 23, no. 1, p. 399, Jun. 2023, doi: 10.1186/s12888-023-04806-9.
- [12] Y. Istikorini, S. N. Rohmah, A. Y. Maulina, D. P. Ardian, F. Z. Navizan, and I. F. Alam, “Penyuluhan Hama dan Penyakit pada Tanaman Padi dan Hortikultura di Desa Cihamerang , Sukabumi (Extension of Pests and Diseases in Rice and Horticultural Plants in Cihamerang Village , Sukabumi),” *J. Pus. Inov. Masy.*, vol. 7, no. April, pp. 102–115, 2025, doi: 10.29244/jpim.7.1.102-115 April.
- [13] A. D. Dhaifulloh, B. I. Khayumi, D. Tirtayuda, M. K. A. A. Legawa, and Denny Oktavina Radianto, “Dampak Penggunaan Pestisida Kimia Terhadap Kualitas Tanah dan Air Sungai di Daerah Pertanian,” *Venus J. Publ. Rumpun Ilmu Tek.*, vol. 2, no. 2, pp. 197–208, Apr. 2024, doi: 10.61132/venus.v2i2.280.
- [14] M. Günay, Ö. Yıldırım, and Y. Demir, “Deep Learning: Evolution, Innovations, And Applications In The Last Decade,” *Middle East J. Sci.*, vol. 11, no. 1, pp. 96–115, Jun. 2025, doi: 10.51477/mejs.1640908.
- [15] T. D. Salka, M. B. Hanafi, S. M. S. A. A. Rahman, D. B. M. Zulperi, and Z. Omar, “Plant leaf disease detection and classification using convolution neural networks model: a review,” *Artif. Intell. Rev.*, vol. 58, no. 10, pp. 1–66, 2025, doi: 10.1007/s10462-025-11234-6.
- [16] D. Pakiding, A. Selo, and W. Wahyuddin, “Implementasi Computer Vision dalam Mendeteksi Penyakit pada Tanaman Cabai dan Tomat Menggunakan Algoritma Convolutional Neural Networks,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. 3, pp. 841–850, Jun. 2025, doi: 10.57152/malcom.v5i3.1989.
- [17] H. Imaduddin, F. Y. A’la, A. Fatmawati, and B. A. Hermansyah, “Comparison of transfer learning method for COVID-19 detection using convolution neural network,” *Bull. Electr. Eng. Informatics*, vol. 11, no. 2, pp. 1091–1099, 2022, doi: 10.11591/eei.v11i2.3525.
- [18] S. Maheswari and D. Gunawan, “Deteksi Dini Kanker Kulit Menggunakan Cnn, Dnn, Dan Efficientnet: Pendekatan Deep Learning Berbasis Web,” *Rabit J. Teknol. dan Sist. Inf. Univrab*, vol. 10, no. 2, pp. 932–944, 2025, doi: 10.36341/rabit.v10i2.6417.
- [19] M. Khoiruddin, A. Junaidi, and W. A. Saputra, “Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network,” *J. Dinda Data Sci. Inf. Technol. Data Anal.*, vol. 2, no. 1, pp. 37–45, Feb. 2022, doi: 10.20895/dinda.v2i1.341.
- [20] A. A. Abhinowo, R. R. Isnanto, and Dania Eridan, “Pemilihan Model Terbaik Algoritma Convolutional Neural Network Untuk Klasifikasi Jenis Bencana Alam The Best Model Selection Of Convolutional Neural Network Algorithm For Natural Disaster Classification,” *J. Tek. Komput.*, vol. 1, no. 4, pp. 199–208, 2023, doi: 10.14710/jtk.v1i4.37656.
- [21] S. Sariah, N. Suarna, I. Ali, and D. Solihudin, “Penerapan Convolutional Neural Network (CNN) Untuk Prediksi Penyakit Tanaman Padi Melalui Citra Daun,” *J. Komtika (Komputasi dan Inform.*, vol. 9, no. 1, pp. 1–10, May 2025, doi: 10.31603/komtika.v9i1.12852.
- [22] R. Suciani et al., “Deteksi penyakit daun padi menggunakan deep learning dengan arsitektur cnn detection of rice leaf disease using deep learning with cnn architecture,” *J. Inf. Technol. Comput. Sci.*, vol. 8, no. 5, pp. 1451–1463, 2025, doi:



<https://doi.org/10.31539/9112kc41>.

- [23] R. Ihza Yuzar Vianda, P. Anjarwati, H. Akbar Pratama, R. Maulana Akbar, and R. Dwi Irawan, “Klasifikasi Citra Bunga Multikelas Menggunakan Convolutional Neural Network (CNN),” *Pros. Semin. Nas. Teknol. Inf. dan Bisnis 2025*, vol. 2025, no. 1, pp. 367–376, Jul. 2025, doi: 10.47701/0d10j421.
- [24] K. R. Ummah, T. Karlita, R. Sigit, E. M. Yuniarno, I. K. E. Purnama, and M. H. Purnomo, “Effect of Image Pre-Processing Method on Convolutional Neural Network Classification of Covid-19 Ct Scan Images,” *Int. J. Innov. Comput. Inf. Control*, vol. 18, no. 6, pp. 1895–1912, 2022, doi: 10.24507/ijicic.18.06.1895.
- [25] A. Cardova and A. Hermawan, “Implementasi Metode LSTM Untuk Mengklasifikasi Berita Palsu Pada PolitiFact,” *J. Fasilkom*, vol. 13, no. 3, pp. 471–479, 2023, doi: 10.37859/jf.v13i3.6175.
- [26] C. Wijayanto and Y. A. Susetyo, “Implementasi Flask Framework Pada Pembangunan Aplikasi Sistem Informasi Helpdesk (SIH),” *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 7, no. 3, pp. 858–868, Aug. 2022, doi: 10.29100/jupi.v7i3.3161.