

Implementasi Convolutional Neural Network (CNN) dalam Diagnosa Penyakit Daun Padi Berdasarkan Citra Digital

Indra Irawan¹, M.Hizbul Wathan², Better Swengky³, Ardi Ramadani⁴

^{1,2,3,4}, Politeknik Manufaktur Negeri Bangka Belitung
Penulis Korespondensi : mhizbul@polman-babel.ac.id

Article Information:

Received: April 18 2025, Accepted: April 27, 2024, Published: April 30 2024

Abstract

This study examines the application of Convolutional Neural Networks (CNNs) in classifying rice leaf diseases using digital images. The model classifies three types of diseases: Bacterial Leaf Blight, Rice Blast, and Rice Tungro Virus. A dataset of 240 images was obtained from Kaggle, with 80 images per class. Four training scenarios were applied using 25, 50, 75, and 100 epochs. Preprocessing steps included resizing all images to 150x150 pixels and normalizing pixel values. Evaluation results show that classification accuracy increases with the number of training epochs. The best model was achieved at 100 epochs, yielding a validation accuracy of 91.67% and testing accuracy of 92%. These results demonstrate that CNN is effective in diagnosing rice leaf diseases and can support early detection efforts, thereby strengthening national food security.

Keywords: Classification, Feature Extraction, CNN, Rice Leaf Disease

1. Pendahuluan

Pertanian merupakan sektor vital yang berkaitan langsung dengan ketahanan pangan nasional, di mana berbagai inovasi teknologi, termasuk kecerdasan buatan, kini banyak diterapkan dalam sektor tersebut [1]. Salah satu komoditas utama dalam sektor pertanian Indonesia adalah *Oryza sativa* atau padi, yang merupakan sumber pangan pokok bagi mayoritas penduduk Indonesia, sekaligus menempati urutan ketiga sebagai biji-bijian yang paling banyak dikonsumsi secara global setelah gandum dan jagung [2]. Namun demikian, produksi padi di Indonesia mengalami tantangan yang cukup signifikan. Berdasarkan data dari Badan Pusat Statistik (BPS), produksi padi Indonesia selama Januari–September 2023 diperkirakan sebesar 45,33 juta ton GKG, mengalami penurunan sekitar 105,09 ribu ton GKG (0,23%) dibandingkan periode yang sama pada tahun 2022. Bahkan jika ditambahkan potensi produksi Oktober–Desember 2023 sebesar 8,30 juta ton GKG, maka total produksi tahun 2023 diperkirakan hanya mencapai 53,63 juta ton GKG, turun 1,12 juta ton (2,05%) dari tahun sebelumnya [3].

Salah satu penyebab penurunan produksi tersebut adalah serangan penyakit tanaman, khususnya yang menyerang bagian daun padi. Penyakit daun padi dapat menurunkan baik kuantitas maupun

kualitas hasil panen secara drastis [4]. Penyakit seperti bacterial leaf blight, leaf smut, dan brown spot adalah beberapa contoh penyakit yang kerap menginfeksi lahan pertanian padi di Indonesia. Sayangnya, penyakit-penyakit ini sering kali tidak terdeteksi secara dini oleh para petani, khususnya petani kecil yang belum memiliki akses pada teknologi identifikasi modern. Hal ini menyebabkan kesalahan

dalam penanganan, serta keterlambatan dalam penanggulangan [5]. Seiring perkembangan teknologi informasi dan komputer, kini dimungkinkan untuk melakukan proses identifikasi penyakit tanaman menggunakan pendekatan *Computer Vision*. Salah satu cabang dari teknologi *Artificial Intelligence* (AI) yang berkembang pesat adalah Machine Learning, yang kemudian melahirkan pendekatan yang lebih kompleks dan canggih yaitu Deep Learning [6]. Deep Learning telah menjadi kekuatan utama dalam transformasi teknologi di berbagai sektor termasuk pertanian [7]. Dibandingkan metode tradisional dalam *Machine Learning*, *Deep Learning* memiliki performa yang lebih unggul dalam hal akurasi dan kemampuan generalisasi [8]. Salah satu model Deep Learning yang paling banyak digunakan untuk pengolahan citra adalah *Convolutional Neural Network* (CNN). CNN dirancang khusus untuk memproses data berbasis gambar dan dikenal memiliki keunggulan dalam mengekstraksi fitur visual secara otomatis [9][10]. Keunggulan CNN terletak pada kemampuannya mengenali pola visual yang kompleks tanpa memerlukan rekayasa fitur secara manual, menjadikannya sangat ideal untuk tugas klasifikasi citra termasuk citra daun padi [11].

Beberapa penelitian telah menunjukkan keberhasilan CNN dalam mengidentifikasi penyakit tanaman berbasis citra. Amelia et al. (2023) menggunakan CNN untuk klasifikasi penyakit daun padi dengan akurasi tinggi namun masih menghadapi tantangan dalam efisiensi waktu pelatihan [12]. Penelitian oleh Damayanti et al. (2021) menemukan bahwa model ResNet50 lebih baik dalam mengenali pola penyakit dibandingkan arsitektur CNN lain [13]. Kurniawan dan Lestari (2022) membuktikan bahwa augmentasi data mampu meningkatkan akurasi CNN secara signifikan [14]. Sementara itu, pendekatan ringan CNN untuk perangkat mobile juga mulai dieksplorasi oleh Syahputra et al. (2024) [15].

Berdasarkan latar belakang tersebut, maka penelitian ini berjudul "Implementasi *Convolutional Neural Network* (CNN) dalam Diagnosa Penyakit Daun Padi Berdasarkan Citra Digital", bertujuan untuk membangun sistem klasifikasi penyakit daun padi yang terdiri dari *blast*, *blight*, dan *tungro* menggunakan model CNN. Penelitian ini juga bertujuan untuk menguji performa model CNN dalam beberapa skenario *epoch* pelatihan, serta memberikan kontribusi dalam bentuk sistem diagnosis berbasis citra guna mendukung peningkatan ketahanan pangan dan membantu petani dalam mendeteksi penyakit secara dini.

2. Tinjauan Literatur

2.1 Klasifikasi

Klasifikasi merupakan proses utama dalam sistem pengenalan pola, yang digunakan untuk mengelompokkan data ke dalam kategori yang telah ditentukan sebelumnya. Dalam konteks pengolahan citra daun padi, klasifikasi digunakan untuk mengidentifikasi jenis penyakit berdasarkan ciri visual tertentu seperti warna, tekstur, dan bentuk [1] [16].

2.2 Convolution Neural Network (CNN)

CNN merupakan arsitektur deep learning yang dirancang khusus untuk pengolahan data visual. CNN bekerja dengan memanfaatkan layer konvolusi dan pooling untuk mengekstraksi fitur spasial dari citra secara otomatis dan efisien [17].


2.3 Feature Extraction

Feature Extraction adalah proses untuk mengekstraksi informasi penting dari citra guna mengurangi dimensi data dan meningkatkan efisiensi proses klasifikasi. Teknik ini sangat penting karena fitur yang relevan membantu model dalam membedakan antar kelas secara akurat. Dalam beberapa studi, metode ekstraksi fitur berbasis CNN telah berhasil mengidentifikasi pola dan tekstur pada daun padi secara otomatis tanpa perlu proses segmentasi manual [17].

3. Metode Penelitian

3.1 Tahapan Penelitian

Penelitian ini memanfaatkan dataset citra daun padi yang diperoleh dari situs penyedia dataset Kaggle.com. Dataset tersebut mencakup tiga jenis penyakit padi, yaitu blast, blight dan tungro. Pendekatan yang digunakan dalam penelitian ini adalah Deep Learning dengan metode *Convolutional Neural Network* (CNN), yang berfungsi untuk mengolah citra daun dan mengklasifikasikan jenis penyakit padi. Klasifikasi merupakan teknik untuk membedakan satu objek dengan objek lainnya. Setelah proses pelatihan model, dilakukan pengujian dengan tiga skenario berbeda. Proses pelatihan dan pengujian model dilakukan menggunakan *Google Colab*, dengan bahasa pemrograman *Python* sebagai media pengkodean. Dalam penelitian ini, terdapat beberapa tahapan yang dilakukan untuk mengklasifikasikan jenis penyakit pada daun tanaman padi, yaitu sebagai berikut:



Gambar 1. Tahapan Penelitian

Tahapan dalam penelitian ini diawali dengan melakukan studi literatur untuk memahami dasar teori dan penelitian terdahulu yang relevan. Selanjutnya, dilakukan pengumpulan dataset berupa citra

daun padi dari sumber terpercaya. Dataset yang diperoleh kemudian melalui tahap preprocessing untuk menyesuaikan format dan kualitas data, seperti mengubah ukuran citra dan normalisasi. Setelah itu, dataset dibagi menjadi dua bagian, yaitu data latih dan data validasi. Tahap berikutnya adalah perancangan arsitektur model *Convolutional Neural Network* (CNN) yang digunakan untuk melakukan klasifikasi. Model yang telah dirancang kemudian dilatih menggunakan data latih, dan hasil pelatihan diuji menggunakan data validasi untuk mengevaluasi performa model.

3.2 Studi Literatur

Studi literatur yang menjadi sumber acuan diperoleh dari jurnal, buku, serta situs web (penelitian daring) yang berkaitan dengan topik *deep learning*, klasifikasi penyakit tanaman, dan metode *Convolutional Neural Network*.

3.3 Pengumpulan Dataset

Pengumpulan data dilakukan dengan menggunakan dataset publik yang diambil dari situs *Kaggle.com* melalui tautan: <https://www.kaggle.com/tedisetiady/leaf-rice-disease-indonesia>. Dataset ini terdiri dari citra daun tanaman padi yang digunakan dalam proses klasifikasi. Terdapat tiga kelas penyakit pada citra yang digunakan, yaitu *Blight*, *Rice Blast*, dan *Tungro Virus*, dengan total keseluruhan gambar sebanyak 240 citra dengan 80 citra daun padi di setiap kelasnya. Citra daun padi menggunakan format .JPG dengan fitur *Red*, *Green*, *Blue* (RGB).

Tabel 1. Dataset

No	Kelas	Blast	Blight	Tungro
1	Jumlah Data	80	80	80
2	Data Training	192	192	92
3	Data Validasi	48	48	48
	Gambar			


3.4 Preprocessing Data

Proses preprocessing data merupakan langkah awal dalam menyiapkan citra sebelum digunakan untuk klasifikasi. Seluruh gambar pada dataset dipotong atau di-crop menjadi ukuran seragam 150x150 piksel untuk memastikan keseragaman dimensi input ke model. Setelah proses cropping selesai, dataset dibagi menjadi dua bagian, yaitu 192 gambar untuk pelatihan (training) dan 48 gambar untuk validasi, sehingga model dapat dilatih dan diuji secara optimal.

3.4 Perancangan Model CNN

Perancangan model ini menggunakan *Convolutional Neural Network* (CNN), yang merupakan salah satu jenis model dalam pembelajaran terawasi yang dirancang untuk memproses input berupa citra atau gambar. Proses desain Model CNN melibatkan serangkaian tahapan yang mengulang antara lapisan *Convolutional* dan *pooling*, yang diakhiri dengan lapisan *fully connected*. Tahapan dimulai dengan pemberian input dataset, dilanjutkan dengan penerapan lapisan *Convolutional*, *RelU*, dan *Maxpooling* yang terdiri dari beberapa lapisan. Selanjutnya, tahap klasifikasi dilakukan pada lapisan *fully connected*, yang mencakup prosedur *flatten* dan *dense*. Output dari Model CNN mencakup

hasil pelatihan yang meliputi nilai akurasi, *loss*, dan *Confusion Matrix*. Berikut adalah arsitektur CNN yang digunakan:



Gambar 2. Arsitektur CNN

3.5 Pelatihan Model

Pada tahap pelatihan model CNN, proses pelatihan atau training dilakukan dengan menggunakan data training dan data validasi. Pada tahap ini, model melakukan prediksi dan perhitungan menggunakan *Confusion Matrix*. Dataset yang ada juga diproses dan kemudian dilatih dengan empat skenario pengujian, yaitu menggunakan 25 *Epoch*, 50 *Epoch*, 75 *Epoch*, dan 100 *Epoch*, dengan masing-masing pembagian 192 data untuk data training dan 16 data untuk data validasi. Tujuan dari variasi skenario ini adalah untuk menentukan skenario yang paling optimal dalam proses pelatihan yang dilakukan.

3.6 Hasil dan Evaluasi


Hasil dan evaluasi merupakan tahap akhir dalam penelitian ini, di mana pada tahap ini akan diperoleh persentase akurasi dari model CNN yang telah dikembangkan. Hasil tersebut akan menjadi dasar dalam menarik kesimpulan dari penelitian yang telah dilaksanakan.

4. Hasil dan Pembahasan

Pada tahap ini disajikan hasil implementasi dari arsitektur model *Convolutional Neural Network* (CNN) yang telah dirancang untuk mendeteksi citra daun dalam rangka klasifikasi penyakit pada tanaman padi dengan pendekatan Deep Learning berbasis CNN. Model CNN yang dikembangkan dalam penelitian ini mampu melakukan prediksi terhadap kondisi tanaman padi dan mengelompokkannya ke dalam kategori penyakit tertentu, sebagaimana dibuktikan melalui data pelatihan (*training*) dan data validasi yang digunakan. Arsitektur CNN yang digunakan mencakup beberapa lapisan utama, yaitu convolution layer, pooling layer, flatten layer, dan dense layer, yang semuanya berperan dalam proses klasifikasi penyakit tanaman padi. Proses pelatihan model dilakukan melalui empat skenario pengujian, yakni: skenario pertama dengan 25 epoch, skenario kedua dengan 50 epoch, skenario ketiga dengan 75 epoch, dan skenario keempat dengan 100 epoch. Setiap proses pelatihan dihentikan setelah mencapai jumlah epoch yang telah ditetapkan pada masing-masing skenario.


4.1 Epoch 25

Berdasarkan hasil pengujian model pada skenario pertama yang menggunakan 25 epoch, diperoleh performa model terhadap data pelatihan dan data validasi dengan rincian sebagai berikut:



Gambar 3. Akurasi *Epoch* 25

Gambar 3 yang menampilkan akurasi *training* dan *validation* pada skenario 1 dengan 25 epoch memperlihatkan grafik perkembangan akurasi model selama proses pelatihan. Pada epoch terakhir, model mencapai akurasi sebesar 0.8549 pada data training dan 0.7708 pada data validasi.



Gambar 4. *Epoch* 25 Confusion Matrix

Pada Gambar 4 yang menampilkan hasil *Confusion Matrix* pada epoch ke-25, terlihat adanya ketidaksesuaian klasifikasi pada kelas *blight* 3 dan *tungro* 8. Berdasarkan *Confusion Matrix* tersebut, diperoleh *classification report* yang merangkum hasil evaluasi model pada tahap pengujian sebagai berikut:


	precision	recall	f1-score	support
blast	0.62	1.00	0.76	16
blight	0.93	0.81	0.87	16
tungro	1.00	0.50	0.67	16
accuracy			0.77	48
macro avg	0.85	0.77	0.77	48
weighted avg	0.85	0.77	0.77	48

Gambar 5. *Epoch 25 Classification Report*

Berdasarkan Gambar 5 yang menunjukkan *Classification Report* pada skenario 1 dengan 25 *epoch*, hasil pengujian model menggunakan *Confusion Matrix* menunjukkan bahwa klasifikasi terhadap penyakit pada tanaman padi mencapai tingkat akurasi sebesar 77%. Nilai akurasi tersebut dipengaruhi oleh adanya ketidaktepatan klasifikasi, yaitu 3 kesalahan pada kelas *blight* dan 8 kesalahan pada kelas *tungro*.


4.2 Epoch 50

Berdasarkan hasil pengujian model pada skenario kedua yang menggunakan 50 *epoch*, diperoleh performa model terhadap data pelatihan dan data validasi dengan rincian sebagai berikut:



Gambar 6. Akurasi *Epoch 50*

Gambar 6 yang menampilkan akurasi *training* dan *validation* pada skenario 2 dengan 50 *epoch* memperlihatkan grafik perkembangan akurasi model selama proses pelatihan. Pada *epoch* terakhir, model mencapai akurasi sebesar 1.0000 pada data training dan 0.8542 pada data validasi.



Gambar 7. Epoch 50 Confusion Matrix

Pada Gambar 7 yang menampilkan hasil *Confusion Matrix* pada epoch ke-50, terlihat adanya ketidaksesuaian klasifikasi pada kelas blast 2, *blight* 4 dan *tungro* 1. Berdasarkan *Confusion Matrix* tersebut, diperoleh *classification report* yang merangkum hasil evaluasi model pada tahap pengujian sebagai berikut:


	precision	recall	f1-score	support
blast	0.88	0.88	0.88	16
blight	1.00	0.75	0.86	16
tungro	0.75	0.94	0.83	16
accuracy			0.85	48
macro avg	0.88	0.85	0.86	48
weighted avg	0.88	0.85	0.86	48

Gambar 8. Epoch 50 Classification Report

Berdasarkan Gambar 8 yang menunjukkan *Classification Report* pada skenario 1 dengan 25 *epoch*, hasil pengujian model menggunakan *Confusion Matrix* menunjukkan bahwa klasifikasi terhadap penyakit pada tanaman padi mencapai tingkat akurasi sebesar 85%. Nilai akurasi tersebut dipengaruhi oleh adanya ketidaktepatan klasifikasi, yaitu 2 kesalahan pada kelas *blast*, 4 kesalahan pada kelas *blight* dan 1 kesalahan pada kelas *tungro*.


4.3 Epoch 75

Berdasarkan hasil pengujian model pada skenario ketiga yang menggunakan 75 epoch, diperoleh performa model terhadap data pelatihan dan data validasi dengan rincian sebagai berikut:



Gambar 9. Akurasi *Epoch* 75

Gambar 9 yang menampilkan akurasi *training* dan *validation* pada skenario 3 dengan 75 *epoch* memperlihatkan grafik perkembangan akurasi model selama proses pelatihan. Pada *epoch* terakhir, model mencapai akurasi sebesar 1.0000 pada data training dan 0.8958 pada data validasi.



Gambar 10. *Epoch* 75 Confusion Matrix

Pada Gambar 10 yang menampilkan hasil *Confusion Matrix* pada epoch ke-75, terlihat adanya ketidaksesuaian klasifikasi pada kelas *blast* 1, dan *blight* 4. Berdasarkan *Confusion Matrix* tersebut, diperoleh *classification report* yang merangkum hasil evaluasi model pada tahap pengujian sebagai berikut:


	precision	recall	f1-score	support
blast	0.94	0.94	0.94	16
blight	0.92	0.75	0.83	16
tungro	0.84	1.00	0.91	16
accuracy			0.90	48
macro avg	0.90	0.90	0.89	48
weighted avg	0.90	0.90	0.89	48

Gambar 11. *Epoch 75 Classification Report*

Berdasarkan Gambar 11 yang menunjukkan *Classification Report* pada skenario 3 dengan 75 *epoch*, hasil pengujian model menggunakan *Confusion Matrix* menunjukkan bahwa klasifikasi terhadap penyakit pada tanaman padi mencapai tingkat akurasi sebesar 90%. Nilai akurasi tersebut dipengaruhi oleh adanya ketidaktepatan klasifikasi, yaitu 1 kesalahan pada kelas *blast*, dan 4 kesalahan pada kelas *blight*.


4.4 Epoch 100

Berdasarkan hasil pengujian model pada skenario keempat yang menggunakan 100 *epoch*, diperoleh performa model terhadap data pelatihan dan data validasi dengan rincian sebagai berikut:



Gambar 12. Akurasi *Epoch* 100

Gambar 12 yang menampilkan akurasi *training* dan *validation* pada skenario 4 dengan 100 *epoch* memperlihatkan grafik perkembangan akurasi model selama proses pelatihan. Pada epoch terakhir, model mencapai akurasi sebesar 1.0000 pada data training dan 0.9167 pada data validasi.



Gambar 13. *Epoch 100 Confusion Matrix*

Pada Gambar 13 yang menampilkan hasil *Confusion Matrix* pada epoch ke-100, terlihat adanya ketidaksesuaian klasifikasi pada kelas *blight* 3, dan *tungro* 1. Berdasarkan *Confusion Matrix* tersebut, diperoleh *classification report* yang merangkum hasil evaluasi model pada tahap pengujian sebagai berikut:

	precision	recall	f1-score	support
blast	0.94	1.00	0.97	16
blight	1.00	0.81	0.90	16
tungro	0.83	0.94	0.88	16
accuracy			0.92	48
macro avg	0.92	0.92	0.92	48
weighted avg	0.92	0.92	0.92	48

Gambar 14. *Epoch 100 Classification Report*

Berdasarkan Gambar 14 yang menunjukkan *Classification Report* pada skenario 3 dengan 75 epoch, hasil pengujian model menggunakan *Confusion Matrix* menunjukkan bahwa klasifikasi terhadap penyakit pada tanaman padi mencapai tingkat akurasi sebesar 92%. Nilai akurasi tersebut dipengaruhi oleh adanya ketidaktepatan klasifikasi, yaitu 3 kesalahan pada kelas *blight*, dan 1 kesalahan pada kelas *tungro*.

4.5 Perbandingan *Epoch*

Pada tahap ini bertujuan untuk menyajikan hasil dari tahapan training, dan validasi model. Hasil yang diperoleh menunjukkan bahwa akurasi model bervariasi pada setiap jumlah epoch, yaitu 25, 50, 75, dan 100. Perbandingan akurasi berdasarkan jumlah epoch tersebut disajikan dalam tabel berikut:

Tabel 5. Perbandingan Epoch

Epoch	Loss	Accuracy	Val Loss	Val Accuracy	Testing	Time (s)
25	0.4558	0.8549	0.7491	0.7708	77 %	321
50	4.7930e-04	1.0000	0.6640	0.8542	85%	732
75	0.0013	1.0000	0.2141	0.8958	90 %	996
100	5.7384e-05	1.0000	0.2239	0.9167	92%	934

Hasil evaluasi dari proses pelatihan yang telah dilakukan menunjukkan bahwa jumlah epoch memiliki pengaruh signifikan terhadap performa model selama pelatihan. Berdasarkan analisis *confusion matrix*. Berdasarkan data yang disajikan pada Tabel 5 mengenai perbandingan jumlah epoch, dapat disimpulkan bahwa model dengan 100 epoch memberikan performa terbaik dibandingkan dengan model pada skenario lainnya. Model ini mampu mencapai tingkat akurasi sebesar 92%, yang menunjukkan bahwa metode CNN yang digunakan efektif dalam melakukan klasifikasi penyakit pada daun padi.

5. Kesimpulan

Berdasarkan hasil pengujian yang dilakukan dalam penelitian ini dengan menggunakan model *Convolutional Neural Network* (CNN), dapat disimpulkan bahwa jumlah epoch yang digunakan dalam proses pelatihan berpengaruh terhadap tingkat akurasi dan hasil evaluasi klasifikasi menggunakan *confusion matrix*. Penelitian ini menggunakan empat skenario pelatihan dengan jumlah epoch berbeda, yaitu 25, 50, 75, dan 100 epoch. Masing-masing skenario menunjukkan performa yang bervariasi baik dalam akurasi pelatihan maupun validasi. Evaluasi menggunakan *confusion matrix* dan *classification report* memperlihatkan bahwa model berhasil memprediksi ketiga kelas penyakit secara akurat, yaitu *blast*, *blight*, dan *tungro*.

Nilai evaluasi klasifikasi menunjukkan bahwa kelas *blast* memiliki precision sebesar 0.94, recall 1.00, dan f1-score 0.97; kelas *blight* memiliki precision 1.00, recall 0.81, dan f1-score 0.90; sedangkan kelas *tungro* menunjukkan precision 0.83, recall 0.94, dan f1-score 0.88. Secara keseluruhan, nilai macro average dan weighted average untuk precision, recall, dan f1-score masing-masing mencapai 0.92, menandakan performa klasifikasi yang seimbang di antara seluruh kelas.

Hasil ini mempertegas bahwa jumlah epoch yang lebih tinggi dapat meningkatkan performa pelatihan model CNN, baik dari segi akurasi maupun kestabilan hasil klasifikasi. Model dengan 100 epoch terbukti lebih unggul dibandingkan skenario dengan jumlah epoch yang lebih rendah. Untuk penelitian selanjutnya, disarankan agar dilakukan pengujian pada dataset yang lebih besar dan lebih bervariasi, serta eksplorasi terhadap arsitektur CNN yang lebih kompleks untuk meningkatkan akurasi dan kemampuan generalisasi model.

Referensi

- [1]. Agustiani, M. (2023). Penerapan Algoritma CNN dalam Identifikasi Penyakit Tanaman. *Jurnal Teknologi Terpadu*, 10(1), 57–66.
- [2]. Badan Pusat Statistik. (2023). *Statistik Tanaman Pangan 2023*. Jakarta: BPS.
- [3]. Badan Pangan Nasional. (2023). *Laporan Tahunan Ketahanan Pangan*. Diakses dari <https://www.bapanas.go.id>

- [4]. Kurniawan, F., & Lestari, N. (2022). Augmentasi dan CNN dalam Klasifikasi Penyakit Tanaman. *Jurnal Ilmu Komputer dan Aplikasi*, 14(3), 78–85.
- [5]. Wijaya, D., et al. (2020). Deteksi Penyakit Daun Padi Berbasis CNN dan Implementasinya pada Aplikasi Android. *Jurnal Informatika Pertanian*, 12(1), 45–53.
- [6]. Damayanti, A., et al. (2021). Perbandingan Arsitektur CNN untuk Deteksi Penyakit Tanaman. *Jurnal Deep Learning Indonesia*, 3(1), 23–34.
- [7]. Syahputra, R., et al. (2024). Model CNN Ringan untuk Diagnosa Penyakit Padi di Perangkat Mobile. *Seminar Nasional Teknologi Informasi*.
- [8]. Rahmadani, S., et al. (2023). Kombinasi CNN dan GLCM untuk Deteksi Penyakit Daun Padi. *Jurnal Komputasi Cerdas*, 5(2), 112–121.
- [9]. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- [10]. Ojsx, M. (2023). Implementasi CNN untuk Klasifikasi Citra Daun. *Jurnal Teknologi Cerdas*.
- [11]. Chollet, F. (2018). *Deep Learning with Python*. Manning Publications.
- [12]. Amelia, R., et al. (2023). Pengembangan Model CNN untuk Deteksi Penyakit Padi. *Prosiding SNATI*.
- [13]. Damayanti, A., et al. (2021). Perbandingan Arsitektur CNN untuk Deteksi Penyakit Tanaman. *Jurnal Deep Learning Indonesia*.
- [14]. Kurniawan, F., & Lestari, N. (2022). Augmentasi dan CNN dalam Klasifikasi Penyakit Tanaman.
- [15]. Syahputra, R., et al. (2024). Model CNN Ringan untuk Diagnosa Penyakit Padi di Perangkat Mobile.
- [16] M. E. Haque *et al.*, "Rice Leaf Disease Classification and Detection Using YOLOv5," *arXiv preprint arXiv:2209.01579*, Sep. 2022. [Online]. Tersedia: <https://arxiv.org/abs/2209.01579>
- [17] Y. Cao, "Detection and classification of pests and diseases in rice leaf images based on deep learning algorithms," *Applied and Computational Engineering*, vol. 74, pp. 219–224, Jul. 2024.

Copyrights

Copyright for this article is retained by the author(s), with first publication rights granted to the journal.

This is an open-access article distributed under the terms and conditions of the Creative Commons Attribution license (<http://creativecommons.org/licenses/by/4.0/>)

