

Klasifikasi Penyakit pada Tanaman Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network

Denis Aji Pangestu ^{(1)*}, Okta Qomaruddin Aziz ⁽²⁾, Cahyo Crysdian ⁽³⁾

Departemen Teknik Informatika, UIN Maulana Malik Ibrahim, Malang, Indonesia

e-mail : denisajipangestu07@gmail.com, okta.qomaruddin@uin-malang.ac.id, cahyo@ti.uin-malang.ac.id.

* Penulis korespondensi.

Artikel ini diajukan 26 Juni 2024, direvisi 1 Maret 2025, diterima 2 Maret 2025, dan dipublikasikan 31 Mei 2025.

Abstract

The agricultural sector is a vital part of the economy, providing food, raw materials, and employment opportunities. In Indonesia, this sector faces significant challenges, such as low interest from younger generations and plant disease issues. Plant disease identification typically requires the expertise of experienced professionals, but this process is time-consuming and costly. This research aims to develop a plant disease classification model using a Convolutional Neural Network (CNN) to assist farmers in identifying diseases in rice, corn, tomato, and potato plants based on leaf images. Testing was conducted with data splitting ratios of 70:30, 80:20, and 90:10, using both single-stage and multi-stage classification methods. The best results were achieved with an 80:20 data ratio using single-stage classification, with an average accuracy of 80%, precision of 80%, recall of 81%, and F1-score of 79%. This study demonstrates that the CNN method is effective in plant disease classification, achieving optimal performance at a 80:20 data ratio and in single-stage classification. It is hoped that this research can help farmers quickly and accurately identify and manage plant diseases, as well as encourage innovation in the agricultural sector. The implementation of CNN in plant disease classification shows great potential in enhancing the efficiency and accuracy of disease detection, ultimately supporting the sustainability and development of the agricultural sector.

Keywords: Classification, Image Classification, Convolutional Neural Network, Plant Disease, Agricultural

Abstrak

Sektor pertanian merupakan bagian penting dalam perekonomian, menyediakan pangan, bahan baku, dan kesempatan kerja. Di Indonesia, sektor ini menghadapi tantangan serius, seperti kurangnya minat generasi muda dan masalah penyakit tanaman. Identifikasi penyakit tanaman biasanya memerlukan ahli yang berpengalaman, namun proses ini memakan waktu dan biaya yang signifikan. Penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit tanaman menggunakan metode Convolutional Neural Network (CNN) untuk membantu petani dalam mengidentifikasi penyakit pada tanaman padi, jagung, tomat, dan kentang berdasarkan citra daun. Pengujian dilakukan dengan rasio pembagian data 70:30, 80:20, dan 90:10, serta menggunakan metode klasifikasi *single stage* dan *multi stage*. Hasil terbaik dicapai dengan rasio data 80:20 menggunakan *single-stage classification*, dengan rata-rata akurasi 80%, presisi 80%, *recall* 81%, dan *F1-score* 79%. Penelitian ini menunjukkan bahwa metode CNN efektif dalam klasifikasi penyakit tanaman, dengan performa optimal pada rasio data 80:20 dan *single-stage classification*. Diharapkan penelitian ini dapat membantu petani dalam mengenali dan mengatasi penyakit tanaman secara cepat dan tepat, serta mendorong inovasi di sektor pertanian. Implementasi CNN dalam klasifikasi penyakit tanaman menunjukkan potensi besar dalam meningkatkan efisiensi dan akurasi deteksi penyakit, yang pada akhirnya mendukung keberlanjutan dan perkembangan sektor pertanian.

Kata Kunci: Klasifikasi, Klasifikasi Gambar, Convolutional Neural Network, Penyakit Tanaman, Pertanian



1. PENDAHULUAN

Sektor pertanian memegang peranan yang krusial dalam perekonomian, tidak hanya sebagai penyedia kebutuhan pangan dan bahan baku, tetapi juga sebagai sumber lapangan pekerjaan yang signifikan (Chellapandi et al., 2021). Di Indonesia, sektor pertanian menghadapi berbagai tantangan yang kompleks, antara lain menurunnya minat generasi muda untuk ikut berkontribusi dalam bidang pertanian serta adanya ancaman serius yang datang dari penyakit tanaman yang berdampak pada produktivitas (Ngadi et al., 2023). Berbagai macam penyakit tanaman yang disebabkan oleh patogen seperti virus, bakteri, jamur atau nematoda telah menyebabkan penurunan hasil panen yang cukup besar (Suganda & Wulandari, 2018). Sebagai contoh, pada tahun 2020, produksi beras di Indonesia mengalami penurunan sebesar 9 persen akibat serangan penyakit tanaman dan faktor lingkungan lainnya. Dampak ekonomi yang disebabkan penyakit tanaman tidak hanya dirasakan secara mikro oleh petani, namun juga memengaruhi ketahanan pangan nasional dan stabilitas harga komoditas pertanian (Tineges et al., 2020).

Identifikasi penyakit tanaman secara konvensional bergantung pada keahlian ahli atau petani berpengalaman melalui pengamatan visual. Namun, pendekatan ini memiliki beberapa keterbatasan, seperti memerlukan waktu yang lama, biaya konsultasi yang tinggi dan ketergantungan pada ketersediaan tenaga ahli (Oktaviana et al., 2021). Dalam konteks ini, identifikasi otomatis penyakit tanaman menjadi solusi yang menjanjikan. Dengan menggunakan teknik klasifikasi citra, gejala penyakit dapat dideteksi secara dini, bahkan pada tahap awal infeksi (Singh & Misra, 2017). Penerapan metode ekstraksi fitur dan *machine learning* memungkinkan identifikasi penyakit tanaman secara akurat tanpa memerlukan kehadiran ahli secara langsung (Ambarwari et al., 2023).

Dalam beberapa tahun terakhir, penelitian tentang identifikasi penyakit tanaman menggunakan teknologi *machine learning* dan *deep learning* telah berkembang pesat. Salah satu metode yang paling banyak digunakan adalah Convolutional Neural Network (CNN), yang dikenal dengan kemampuannya dalam memproses citra digital secara kompleks (Anggiratih et al., 2021; Rodríguez-Lira et al., 2024; Tugrul et al., 2022; Upadhyay et al., 2025). CNN meniru cara kerja korteks visual manusia dan mampu mempelajari fitur-fitur penting dari citra secara otomatis. Metode ini terdiri dari tiga lapisan utama, yaitu *convolution layer*, *pooling layer*, dan *fully-connected layer*, yang bekerja bersama untuk mengklasifikasikan citra dengan akurasi tinggi (Guo & Wang, 2022).

Pengembangan model CNN untuk klasifikasi penyakit tanaman berdasarkan citra daun pernah dilakukan oleh Anggraeni et al. (2022) terkait klasifikasi penyakit tanaman cabai menggunakan Convolutional Neural Network (CNN) dengan arsitektur terdiri dari 3 lapisan konvolusi, 3 *fully connected layer*, dan satu lapisan *output*. *Dataset* diambil dari Kaggle, terdiri dari tiga kelas: *health*, *leaf curl*, dan *yellowish*. Data dibagi menjadi 80% untuk *training*, 10% untuk validasi, dan 10% untuk pengujian. Dari total 300 data citra, model mencapai akurasi 80% pada *training* dan 60% pada validasi dengan 100 data.

Irfansyah et al. (2021) melakukan penelitian yang mengkaji klasifikasi penyakit akibat hama pada tanaman kopi menggunakan Convolutional Neural Network (CNN) dengan arsitektur AlexNet. Identifikasi dilakukan melalui citra daun menggunakan *dataset* ReCoLe dari Mendeley, yang terdiri dari 300 data terbagi dalam tiga kelas: *health*, *rust*, dan *red spider mite*. Data dibagi dengan rasio 80:20 untuk *training* dan *testing*, dengan akurasi dianggap baik jika >70%. *Training* dengan 260 data latih menghasilkan akurasi 69,44% – 80,56%, sementara pengujian dengan 40 data uji mencapai 81,6%. Hasil ini menunjukkan bahwa AlexNet akurat untuk klasifikasi penyakit tanaman kopi berbasis citra daun.

Penelitian yang dilakukan oleh Sabrina & Maki (2022) membahas klasifikasi penyakit tanaman apel dari citra daun menggunakan Convolutional Neural Network (CNN). *Dataset* diambil dari Kaggle dan disusun dalam direktori *train* (7.700 data) dan *valid* (1.943 data), dengan total 9.643 citra yang terbagi dalam 4 kelas: *apple scab*, *black rot*, *rust*, dan *healthy*. Citra berukuran 256×256



piksel dalam format RGB. Model dapat dijalankan pada *smartphone* dengan Android Lollipop ke atas. Hasil *final test accuracy* dari seluruh proses pelatihan mencapai 97,1%.

Penelitian berikutnya oleh Zalvadila (2023) tentang klasifikasi penyakit bawang merah menggunakan Convolutional Neural Network (CNN) dan Support Vector Machine (SVM) dengan kernel RBF, *linear*, sigmoid, dan *polynomial*. Penelitian ini menerapkan Gray Level Co-occurrence Matrix (GLCM) untuk ekstraksi fitur. *Dataset* terdiri dari 320 citra, terbagi dalam dua kelas: bercak ungu dan moler, masing-masing 160 gambar. Hasil pengujian menunjukkan bahwa CNN dan SVM dengan kernel *linear*, RBF, dan *polynomial* mencapai akurasi, presisi, *recall*, dan *F1-score* 100%. Sementara itu, SVM dengan kernel sigmoid menggunakan GLCM memperoleh akurasi 75%, presisi 75%, *recall* 73%, dan *F1-score* 74%.


Berdasarkan penelitian sebelumnya, Convolutional Neural Network (CNN) terbukti mampu melakukan klasifikasi citra digital dengan tingkat akurasi tinggi dan kemudahan dalam penggunaannya. Oleh karena itu, penelitian ini memilih CNN sebagai metode utama untuk klasifikasi buah segar dan busuk. Dengan menerapkan metode ini, diharapkan dapat diperoleh hasil klasifikasi yang akurat dan andal dalam mengidentifikasi kondisi buah berdasarkan citra digital.

2. METODE PENELITIAN

Penelitian ini akan menggunakan metode *Convolutional Neural Network* (CNN). *Convolutional Neural Network* (CNN) adalah algoritma Deep Learning yang digunakan untuk pengenalan citra, dengan fitur seperti struktur sederhana, sedikit parameter *training*, dan adaptabilitas. CNN juga dapat digunakan untuk analisis suara dan pengenalan pola (Irfansyah et al., 2021).

CNN biasanya digunakan untuk mengidentifikasi perpindahan, *zoom*, dan distorsi lain dari grafik dua dimensi. Karena lapisan ekstraksi fitur CNN belajar dari data *training*, ekstraksi fitur secara eksplisit dari data *training* dapat dihindari (Hasan et al., 2021). Neuron pada bidang *feature map* yang sama memiliki bobot yang sama, memungkinkan jaringan belajar secara bersamaan, yang merupakan keuntungan utama dibandingkan jaringan saraf yang terhubung satu sama lain, dan mengurangi kompleksitas jaringan (Felix et al., 2020).

Dalam penelitian ini, dijelaskan secara sistematis langkah-langkah yang dilakukan dari awal hingga akhir. Proses ini mencakup pengumpulan data, desain sistem, implementasi metode menggunakan algoritma Convolutional Neural Network, pengujian, dan analisis hasil. Penelitian ini menggunakan bahasa pemrograman Python untuk membangun modelnya. Gambar 1 akan menampilkan urutan tahapan penelitian sesuai dengan yang dijelaskan sebagai berikut.



Gambar 1 Desain Tahap Penelitian

2.1 Pengumpulan Data

Dalam penelitian ini, untuk melakukan klasifikasi penyakit tanaman berdasarkan citra daun, dibutuhkan *dataset* citra daun dari empat jenis tanaman, yaitu padi, jagung, tomat, dan kentang. *Dataset* yang digunakan adalah “*New Plant Disease Dataset*” dan “*Rice Leaf Disease Image Sample*” yang diperoleh dari situs web data.mendeley.com dan kaggle.com. *Dataset* ini mencakup empat spesies tanaman dengan total 12 kelas yang berbeda, terdiri dari 1200 citra




daun dalam format .JPG, dengan masing-masing kelas memiliki 100 citra daun untuk klasifikasi penyakit tanaman. Tabel 1 menunjukkan beberapa contoh data yang digunakan dalam penelitian.

Tabel 1 Contoh Data

No.	Nama Tanaman	Nama Penyakit Tanaman	Citra Daun
1	Jagung	Common Rust	
2	Jagung	Healthy	
3	Jagung	Northern Leaf Blight	
4	Kentang	Early Blight	
5	Kentang	Healthy	
6	Kentang	Late Blight	
7	Padi	Brown Spot	
8	Padi	Healthy	
9	Padi	Scald	
10	Tomat	Bacterial Spot	
11	Tomat	Healthy	
12	Tomat	Mosaic Virus	


2.2 Desain Sistem

Gambar 2 dan 3 menunjukkan alur proses klasifikasi penyakit tanaman pangan. Proses ini dimulai dengan input data yang dibagi menjadi data pelatihan (*training data*) dan data pengujian (*testing data*). Setiap kelas memiliki 100 citra daun sebagai input. Selanjutnya, data tersebut melalui tahap *preprocessing* yang mencakup pengolahan seperti *rotate*, *zoom*, vertikal *flip*, dan horizontal *flip*. Setelah *preprocessing*, data diproses menggunakan metode Convolutional Neural Network (CNN). Penelitian ini menghasilkan 12 kelas dari proses klasifikasi, yaitu *corn common rust*, *corn healthy*, *corn northern leaf blight*, *potato early blight*, *potato healthy*, *potato late blight*, *rice brown spot*, *rice healthy*, *rice scald*, *tomato bacterial spot*, *tomato healthy*, dan *tomato mosaic virus*. Hasil klasifikasi tersebut kemudian ditampilkan sebagai *output* untuk memberikan informasi tentang penyakit pada tanaman pangan.



Gambar 2 Desain Sistem Klasifikasi Penyakit Tanaman






Gambar 3 Alur Proses Pengolahan Data

2.3 Metode Convolutional Neural Network

Dalam penelitian ini, Convolutional Neural Network (CNN) diaplikasikan untuk mengklasifikasikan penyakit tanaman berdasarkan citra daun. Arsitektur Convolutional Neural Network (CNN) yang digunakan adalah LeNet-5 dengan beberapa modifikasi, sebagaimana ditunjukkan pada Gambar 4. Arsitektur ini terdiri dari beberapa lapisan utama, yaitu *input layer*, 3 *convolution layer*, 3 *max pooling layer*, *flatten layer*, *dense layer*, dan *output layer*. Berikut penjelasan aplikatif mengenai bagaimana data gambar hasil *preprocessing* diproses oleh CNN.



Gambar 4 Arsitektur CNN LenNet-5



2.3.1 Input Layer

Citra daun yang telah melalui tahap *preprocessing* (seperti *rotate*, *zoom*, *vertikal flip*, dan *horizontal flip*) diubah menjadi matriks piksel dengan ukuran 128x128x1 (*grayscale*). Matriks ini menjadi input untuk CNN. Citra *grayscale* dipilih untuk mengurangi kompleksitas komputasi karena hanya memiliki satu saluran (*channel*) dibandingkan dengan citra RGB yang memiliki tiga saluran.

2.3.2 Convolution Layer

Pada tahap ini, fitur-fitur penting dari citra daun diekstraksi menggunakan kernel/filter. Dalam penelitian ini digunakan kernel dengan ukuran 3x3 akan melakukan konvolusi pada matriks input untuk menghasilkan *feature map*. Proses ini dilakukan secara berulang pada tiga *convolution layer* yang ada, di mana setiap *layer* akan menghasilkan *feature map* yang lebih abstrak dan representatif. Pada citra *grayscale*, konvolusi dilakukan pada satu saluran (*channel*), sehingga komputasi menjadi lebih efisien. Pers. (1) yang ditunjukkan merupakan perhitungan digunakan dalam perhitungan proses konvolusi. Di mana $c_{(a,b)}$ adalah nilai *feature maps*, $X_{(a,b)}$ adalah nilai *input*, dan $W_{(i,j)}$ adalah nilai *kernel*.

$$c_{(a,b)} = \sum_{i=0}^{k_h-1} \sum_{j=0}^{k_w-1} X_{(a+i,b+j)} W_{(i,j)} \quad (1)$$

2.3.3 Max Pooling Layer

Setelah proses konvolusi, *feature map* yang dihasilkan akan direduksi dimensinya menggunakan *max pooling*. Dalam penelitian ini digunakan *max pooling* dengan ukuran 2x2 akan mengambil nilai maksimum dari setiap wilayah 2x2 pada *feature map*, sehingga mengurangi dimensi *feature map* menjadi setengahnya. Hal ini membantu mengurangi kompleksitas komputasi dan mencegah *overfitting*. Berikut adalah Pers. (2) yang digunakan dalam perhitungan ini, di mana $m_{(p,q)}$ merupakan *output feature map* hasil perhitungan, $\max(c_{a \times s_x + p, b \times s_y + q})$ adalah perhitungan untuk mencari nilai tertinggi, serta s_x dan s_y adalah *stride*.

$$m_{(p,q)} = \max(c_{a \times s_x + p, b \times s_y + q}) \quad (2)$$

2.3.4 Flatten Layer

Feature map yang dihasilkan dari *convolution* dan *pooling layer* berbentuk 2D. Sebelum dilanjutkan ke proses klasifikasi, *feature map* tersebut harus diubah menjadi vektor 1D. Vektor satu dimensi ini kemudian digunakan sebagai input untuk *fully connected layer*.

2.3.5 Fully Connected Layer

Pada tahap ini, vektor hasil *flattening* akan diproses melalui beberapa *dense layer* untuk melakukan klasifikasi. *Hidden layer* menggunakan fungsi aktivasi ReLU untuk memperkenalkan non-linearitas, sedangkan *output layer* menggunakan fungsi aktivasi *softmax* untuk menghasilkan probabilitas dari setiap kelas penyakit tanaman. Tujuan utama *fully connected layer* adalah mengklasifikasikan data dengan tepat.

Pers. (3) sampai (5) menunjukkan proses perhitungan yang terjadi dalam *feed forward*. Di mana z_s adalah node pada *hidden layer*, x_d adalah nilai *input*, w_r adalah bobot, b_n adalah nilai bias, a_h adalah nilai aktivasi fungsi *ReLU*, serta $\hat{y}$ adalah perhitungan *softmax* dan perhitungan *loss function* menggunakan *cross-entropy loss*. Pers. (6) sampai (10) menunjukkan proses perhitungan yang terjadi dalam *backward*. Di mana δ_n adalah nilai *error*, $\frac{dL}{dw}$ adalah turunan dari bobot, $\frac{dL}{db_n}$ adalah turunan dari bias, serta $W_n(new)$ dan $b_n(new)$ adalah *update* bobot dan bias.



$$z_s = \sum_{r=0} x_d w_r + b_n \quad (3)$$

$$a_h = \max(0, a_g) \quad (4)$$

$$f(p_i) = \frac{\exp(p_i)}{\sum_{j=0}^{12} \exp(p_j)} \quad (5)$$

$$\delta_n = (y - o_t) \quad (6)$$

$$\frac{dL}{dV} = \delta_n(z)^T \quad (7)$$

$$\frac{dL}{db_n} = \delta_n \quad (8)$$

$$W_n(new) = W_n - \eta \frac{dL}{dW} \quad (9)$$

$$b_n(new) = b_n - \eta \frac{dL}{db_n} \quad (10)$$

2.4 Spesifikasi Komputasi

Penelitian ini menggunakan platform komputasi *cloud* yang disediakan oleh Kaggle.com. Spesifikasi komputasi yang digunakan adalah sebagai berikut:

- CPU: 2 vCPU Intel Xeon.
- GPU: NVIDIA Tesla P100 (16GB VRAM) atau Tesla T4 (16GB VRAM) tergantung pada ketersediaan sumber daya Kaggle.
- RAM: 13GB
- Penyimpanan: 20GB (Kaggle Dataset Storage), 5 GB untuk penyimpanan sementara selama proses pelatihan dan pengujian.

Penggunaan GPU pada platform Kaggle memungkinkan proses pelatihan model CNN berjalan lebih cepat karena kemampuan GPU dalam menangani komputasi paralel yang intensif, terutama dalam operasi matriks yang dominan dalam proses konvolusi dan backpropagation.


3. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan pembagian dataset sebagai skenario pengujian dengan rasio 70:30, 80:20, dan 90:10 untuk *training* dan *testing*. Selain itu, diterapkan dua metode klasifikasi, yaitu *single-stage classification* dan *multi-stage classification* (Żarski et al., 2021). Tabel 2 dan Gambar 5 menampilkan skema *stage classification* dan pembagian skenario model. Enam skenario tersebut dilatih selama 300 *epoch* dengan *learning rate* sebesar 0,001, yang bertujuan untuk memperoleh hasil yang optimal. Setelah model dilatih, dilakukan perhitungan *confusion matrix* untuk mengevaluasi performa klasifikasi (Nawwar et al., 2021).

Tabel 2 Pembagian Skenario Model

Uji Coba	Model Klasifikasi	Data Latih	Data Uji
1	<i>Single-stage classification</i>	70%	30%
2		80%	20%
3		90%	10%
4	<i>Multi-stage classification</i>	70%	30%
5		80%	20%
6		90%	10%





Gambar 5 Contoh Stage Classification

Skenario model 1 menggunakan *single-stage classification* dengan rasio 70:30, melibatkan 840 data latih dan 360 data uji. Tabel 3 menampilkan confusion matrix multi-kelas beserta nilai *precision*, *recall*, dan *F1-score* untuk 12 kelas penyakit tanaman berdasarkan citra daun. Skenario model 2 menggunakan pendekatan yang sama dengan rasio 80:20, memanfaatkan 960 data latih dan 240 data uji; hasilnya ditampilkan pada Tabel 4. Skenario model 3 juga menerapkan *single-stage classification* dengan rasio 90:10, terdiri atas 1.080 data latih dan 120 data uji, dengan hasil yang ditunjukkan pada Tabel 5.

Skenario model 4 menggunakan *multi-stage classification* dengan rasio 70:30, terdiri dari 840 data latih dan 360 data uji, sebagaimana tercantum pada Tabel 6. Skenario model 5 menerapkan metode yang sama dengan rasio 80:20, melibatkan 960 data latih dan 240 data uji; hasilnya tercantum pada Tabel 7. Terakhir, skenario model 6 menggunakan *multi-stage classification* dengan rasio 90:10, menggunakan 1.080 data latih dan 102 data uji, dengan hasil klasifikasi yang disajikan pada Tabel 8.

Tabel 3 Nilai dari Confusion Matrix Skenario Model 1

Kelas Jenis Penyakit	Precision	Recall	F1-Score
<i>Corn Common Rust</i>	45%	60%	51%
<i>Corn Healthy</i>	70%	78%	74%
<i>Corn Northern Leaf Blight</i>	90%	60%	72%
<i>Potato Early Blight</i>	95%	100%	97%
<i>Potato Healthy</i>	80%	76%	78%
<i>Potato Late Blight</i>	55%	69%	61%
<i>Rice Brown Spot</i>	60%	86%	71%
<i>Rice Healthy</i>	85%	100%	92%
<i>Rice Scald</i>	100%	77%	87%
<i>Tomato Bacterial Spot</i>	100%	83%	91%
<i>Tomato Healthy</i>	75%	100%	86%
<i>Tomato Mosaic Virus</i>	100%	80%	89%
Accuracy			74%



Tabel 4 Nilai dari *Confusion Matrix* Skenario Model 2

Kelas Jenis Penyakit	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Corn Common Rust</i>	20%	67%	31%
<i>Corn Healthy</i>	90%	68%	77%
<i>Corn Northern Leaf Blight</i>	83%	58%	68%
<i>Potato Early Blight</i>	87%	84%	85%
<i>Potato Healthy</i>	53%	80%	64%
<i>Potato Late Blight</i>	63%	58%	60%
<i>Rice Brown Spot</i>	27%	100%	42%
<i>Rice Healthy</i>	93%	78%	85%
<i>Rice Scald</i>	97%	67%	79%
<i>Tomato Bacterial Spot</i>	90%	96%	93%
<i>Tomato Healthy</i>	97%	85%	91%
<i>Tomato Mosaic Virus</i>	93%	80%	86%
Accuracy			80%

Tabel 5 *Confusion Matrix* Skenario Model 3

Kelas Jenis Penyakit	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Corn Common Rust</i>	10%	25%	14%
<i>Corn Healthy</i>	80%	80%	80%
<i>Corn Northern Leaf Blight</i>	90%	50%	64%
<i>Potato Early Blight</i>	90%	100%	95%
<i>Potato Healthy</i>	90%	75%	82%
<i>Potato Late Blight</i>	50%	83%	62%
<i>Rice Brown Spot</i>	50%	100%	67%
<i>Rice Healthy</i>	100%	83%	91%
<i>Rice Scald</i>	100%	83%	91%
<i>Tomato Bacterial Spot</i>	90%	90%	90%
<i>Tomato Healthy</i>	90%	100%	95%
<i>Tomato Mosaic Virus</i>	100%	77%	87%
Accuracy			78%

Tabel 6 *Confusion Matrix* Hasil Stage 1 dan 2 Skenario Model 4

Kelas Jenis Penyakit	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Corn Common Rust</i>	30%	68%	42%
<i>Corn Healthy</i>	70%	74%	71%
<i>Corn Northern Leaf Blight</i>	83%	50%	62%
<i>Potato Early Blight</i>	78%	93%	86%
<i>Potato Healthy</i>	45%	83%	59%
<i>Potato Late Blight</i>	81%	61%	69%
<i>Rice Brown Spot</i>	13%	100%	24%
<i>Rice Healthy</i>	97%	54%	71%
<i>Rice Scald</i>	95%	94%	94%
<i>Tomato Bacterial Spot</i>	97%	86%	90%
<i>Tomato Healthy</i>	87%	87%	86%
<i>Tomato Mosaic Virus</i>	100%	86%	92%
Accuracy			73%



Tabel 7 Confusion Matrix Hasil Stage 1 dan 2 Skenario Model 5

Kelas Jenis Penyakit	Precision	Recall	F1-Score
Corn Common Rust	30%	64%	40%
Corn Healthy	75%	79%	77%
Corn Northern Leaf Blight	90%	52%	67%
Potato Early Blight	87%	87%	86%
Potato Healthy	57%	72%	63%
Potato Late Blight	61%	74%	67%
Rice Brown Spot	49%	100%	66%
Rice Healthy	97%	74%	83%
Rice Scald	97%	87%	91%
Tomato Bacterial Spot	93%	79%	86%
Tomato Healthy	88%	84%	86%
Tomato Mosaic Virus	98%	88%	93%
Accuracy			76%

Tabel 8 Confusion matrix Hasil Stage 1 dan 2 Skenario Model 6


Kelas Jenis Penyakit	Precision	Recall	F1-Score
Corn Common Rust	54%	67%	60%
Corn Healthy	45%	83%	59%
Corn Northern Leaf Blight	72%	53%	61%
Potato Early Blight	93%	85%	88%
Potato Healthy	74%	68%	71%
Potato Late Blight	65%	82%	73%
Rice Brown Spot	100%	83%	90%
Rice Healthy	90%	82%	86%
Rice Scald	90%	91%	90%
Tomato Bacterial Spot	65%	73%	69%
Tomato Healthy	74%	83%	78%
Tomato Mosaic Virus	93%	77%	85%
Accuracy			76%

3.1 Pembahasan


Berdasarkan analisis hasil penelitian ini, dari enam model yang dievaluasi, model 2 menunjukkan performa tertinggi dengan akurasi 80%, presisi 80%, *recall* 81%, dan *F1-score* 79%. Keunggulan ini menunjukkan bahwa metode yang digunakan lebih efektif dalam mengklasifikasikan penyakit tanaman pangan dibandingkan skenario lainnya seperti yang ditunjukkan pada Gambar 6. Berdasarkan *confusion matrix* yang ditunjukkan pada Gambar 7 dengan nilai rinciannya pada Tabel 9, kesalahan klasifikasi lebih sering terjadi pada kelas dengan kemiripan warna dan tekstur, seperti Corn Common Rust vs. Corn Northern Leaf Blight, serta Potato Late Blight vs. Potato Healthy. Kesalahan ini kemungkinan dipengaruhi oleh pencahayaan saat pengambilan gambar dan kemiripan fitur tekstur antar kelas penyakit.

Pada *multi-stage classification*, meskipun akurasi keseluruhan lebih rendah dibandingkan *single-stage*, beberapa kelas menunjukkan peningkatan *recall* dan *F1-score*, yang berarti metode ini mampu mengenali beberapa jenis penyakit dengan lebih baik. Gambar 8 membandingkan performa *single-stage* dan *multi-stage classification*. Hasil menunjukkan bahwa *single-stage classification* memiliki performa terbaik secara keseluruhan. Namun, perbedaan performa antara kedua metode ini tidak terlalu signifikan.





Gambar 6 Perbandingan Model Per Rasio Data




Gambar 7 Confusion Matrix Data Uji Skenario 2

Tabel 9 Nilai dari Confusion Matrix Skenario Model 2

Kelas Jenis Penyakit	Precision	Recall	F1-Score
<i>Corn Common Rust</i>	20%	67%	31%
<i>Corn Healthy</i>	90%	68%	77%
<i>Corn Northern Leaf Blight</i>	83%	58%	68%
<i>Potato Early Blight</i>	87%	84%	85%
<i>Potato Healthy</i>	53%	80%	64%
<i>Potato Late Blight</i>	63%	58%	60%
<i>Rice Brown Spot</i>	27%	100%	42%
<i>Rice Healthy</i>	93%	78%	85%
<i>Rice Scald</i>	97%	67%	79%
<i>Tomato Bacterial Spot</i>	90%	96%	93%
<i>Tomato Healthy</i>	97%	85%	91%
<i>Tomato Mosaic Virus</i>	93%	80%	86%
Accuracy			80%





Gambar 8 Perbandingan Model Per Stage

Perbedaan utama terletak pada kecepatan konvergensi, di mana *single-stage classification* mencapai konvergensi pada *epoch* ke-300, sementara *multi-stage classification* masih mengalami sedikit fluktuasi. Hal ini menunjukkan bahwa single-stage lebih efisien dalam waktu pelatihan, sedangkan *multi-stage* dapat meningkatkan performa klasifikasi pada kelas tertentu. Meskipun *single-stage classification* lebih cepat dalam mencapai kestabilan, klasifikasi bertahap memberikan hasil yang lebih akurat dan stabil untuk beberapa kelas penyakit tanaman. Ini menegaskan bahwa meskipun single-stage lebih efisien dalam hal waktu pelatihan, *multi-stage classification* memiliki potensi untuk meningkatkan akurasi pada kelas-kelas tertentu yang lebih sulit diklasifikasikan.

4. KESIMPULAN

Penelitian ini mengevaluasi performa metode Convolutional Neural Network (CNN) dengan arsitektur LeNet-5 dalam klasifikasi penyakit tanaman pangan. Pengujian mencakup *preprocessing* data dengan metode *resize*, *rotate*, *zoom*, *flip*, dan *grayscale*, serta skenario klasifikasi *single-stage* dan *multi-stage* dengan rasio 70:30, 80:20, dan 90:10 untuk data latih dan uji. Hasil pengujian menunjukkan bahwa model 2 memiliki performa terbaik dengan akurasi 80%, presisi 80%, *recall* 81%, dan *F1-Score* 79%, serta berhasil mendeteksi 191 dari 240 data uji. Meskipun terdapat 49 kesalahan prediksi, terutama pada klasifikasi penyakit tanaman jagung, model ini menunjukkan potensi besar dalam penerapan nyata untuk membantu petani mengidentifikasi penyakit tanaman.

Namun, model lain dalam penelitian ini tidak mencapai performa yang setinggi model 2. Model dengan rasio 70:30 dan 90:10 menunjukkan akurasi yang lebih rendah karena beberapa faktor. Pada rasio 70:30, jumlah data latih yang lebih sedikit menyebabkan model kurang mampu mengenali pola dengan baik, sehingga performa prediksi menurun. Sementara itu, pada rasio 90:10, meskipun data latih lebih banyak, jumlah data uji yang lebih sedikit membuat model berisiko mengalami *overfitting*, di mana model lebih cenderung menghafal data latih daripada belajar pola umum yang dapat digeneralisasi. Selain itu, metode *multi-stage classification* menunjukkan konvergensi yang lebih lambat dibandingkan *single-stage classification*, yang mengakibatkan model belum sepenuhnya stabil dalam mendeteksi beberapa jenis penyakit tertentu.

Untuk meningkatkan akurasi, terutama pada penyakit yang sulit diklasifikasikan, penelitian di masa depan dapat mempertimbangkan beberapa strategi:

- 1) Menggunakan *dataset* yang lebih besar dan beragam guna meningkatkan generalisasi model.



- 2) Menerapkan teknik augmentasi data yang lebih kompleks, seperti perubahan warna dan pencahayaan, untuk mengatasi variasi dalam citra daun.
 - 3) Menggabungkan metode CNN dengan model lain, seperti Hybrid CNN-SVM untuk meningkatkan ketepatan klasifikasi.
 - 4) Menyesuaikan arsitektur CNN dengan kedalaman dan jumlah filter yang optimal untuk meningkatkan representasi fitur tanpa meningkatkan risiko *overfitting*.
 - 5) Melakukan *fine-tuning hyperparameter* yang lebih menyeluruh, termasuk penyesuaian *learning rate*, jumlah *epoch*, dan fungsi aktivasi, agar model dapat belajar lebih efektif.
- Dengan penyempurnaan lebih lanjut, model ini diharapkan dapat menjadi solusi yang lebih akurat dan andal dalam deteksi penyakit tanaman, memberikan manfaat besar bagi sektor pertanian.

DAFTAR PUSTAKA

- Ambarwari, A., Husni, E. M., & Mahayana, D. (2023). Perkembangan Paradigma Metode Klasifikasi Citra Penginderaan Jauh dalam Perspektif Revolusi Sains Thomas Kuhn. *Jurnal Filsafat Indonesia*, 6(3), 465–473. <https://doi.org/10.23887/jfi.v6i3.53865>
- Anggiratih, E., Siswanti, S., Octaviani, S. K., & Sari, A. (2021). Klasifikasi Penyakit Tanaman Padi Menggunakan Model Deep Learning EfficientNet B3 dengan Transfer Learning. *Jurnal Ilmiah SINUS*, 19(1), 75–83. <https://doi.org/10.30646/sinus.v19i1.526>
- Anggraeni, D. S., Widayana, A., Rahayu, P. D., & Rozikin, C. (2022). Metode Algoritma Convolutional Neural Network pada Klasifikasi Penyakit Tanaman Cabai. *STRING (Satuan Tulisan Riset dan Inovasi Teknologi)*, 7(1), 73–78. <https://doi.org/10.30998/string.v7i1.13304>
- Chellapandi, B., Vijayalakshmi, M., & Chopra, S. (2021). Comparison of Pre-Trained Models Using Transfer Learning for Detecting Plant Disease. *2021 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)*, 383–387. <https://doi.org/10.1109/ICCCIS51004.2021.9397098>
- Felix, F., Wijaya, J., Sutra, S. P., Kosasih, P. W., & Sirait, P. (2020). Implementasi Convolutional Neural Network Untuk Identifikasi Jenis Tanaman Melalui Daun. *Jurnal SIFO Mikroskil*, 21(1), 1–10. <https://doi.org/10.55601/jsm.v21i1.672>
- Guo, Y., & Wang, X. (2022). Modulation Signal Classification Algorithm Based on Denoising Residual Convolutional Neural Network. *IEEE Access*, 10, 121733–121740. <https://doi.org/10.1109/ACCESS.2022.3221475>
- Hasan, Moh. A., Riyanto, Y., & Riana, D. (2021). Grape Leaf Image Disease Classification Using CNN-VGG16 Model. *Jurnal Teknologi dan Sistem Komputer*, 9(4), 218–223. <https://doi.org/10.14710/jtsiskom.2021.14013>
- Irfansyah, D., Mustikasari, M., & Suroso, A. (2021). Arsitektur Convolutional Neural Network (CNN) Alexnet untuk Klasifikasi Hama pada Citra Daun Tanaman Kopi. *Jurnal Informatika: Jurnal Pengembangan IT*, 6(2), 87–92. <https://doi.org/10.30591/jpit.v6i2.2802>
- Nawwar, N., Kasban, H., & Salama, M. (2021). Improvement of Confusion Matrix for Hand Vein Recognition Based on Deep-Learning Multi-Classifer Decisions. *Arab Journal of Nuclear Sciences and Applications*, 54(4), 133–146. <https://doi.org/10.21608/ajnsa.2021.70450.1460>
- Ngadi, N., Zaelany, A. A., Latifa, A., Harfina, D., Asiati, D., Setiawan, B., Ibnu, F., Triyono, T., & Rajagukguk, Z. (2023). Challenge of Agriculture Development in Indonesia: Rural Youth Mobility and Aging Workers in Agriculture Sector. *Sustainability*, 15(2), Article ID: 922. <https://doi.org/10.3390/su15020922>
- Oktaviana, U. N., Hendrawan, R., Annas, A. D. K., & Wicaksono, G. W. (2021). Klasifikasi Penyakit Padi berdasarkan Citra Daun Menggunakan Model Terlatih ResNet101. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 5(6), 1216–1222. <https://doi.org/10.29207/resti.v5i6.3607>
- Rodríguez-Lira, D.-C., Córdova-Esparza, D.-M., Álvarez-Alvarado, J. M., Terven, J., Romero-González, J.-A., & Rodríguez-Reséndiz, J. (2024). Trends in Machine and Deep Learning Techniques for Plant Disease Identification: A Systematic Review. *Agriculture*, 14(12), Article ID: 2188. <https://doi.org/10.3390/agriculture14122188>
- Sabrina, S. A., & Maki, W. F. A. (2022). Klasifikasi Penyakit pada Tanaman Kopi Robusta Berdasarkan Citra Daun Menggunakan Convolutional Neural Network. *EProceedings of*



- Engineering*, 9(3), 1919–1927.
<https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/17997>
- Singh, V., & Misra, A. K. (2017). Detection of Plant Leaf Diseases Using Image Segmentation and Soft Computing Techniques. *Information Processing in Agriculture*, 4(1), 41–49.
<https://doi.org/10.1016/j.inpa.2016.10.005>
- Suganda, T., & Wulandari, D. Y. (2018). Curvularia sp. Jamur Patogen Baru Penyebab Penyakit Bercak Daun pada Tanaman Sawi. *Jurnal Agrikultura*, 29(3), 119–123.
<https://doi.org/10.24198/agrikultura.v29i3.22716>
- Tineges, R., Triayudi, A., & Sholihati, I. D. (2020). Analisis Sentimen Terhadap Layanan Indihome Berdasarkan Twitter dengan Metode Klasifikasi Support Vector Machine (SVM). *Jurnal Media Informatika Budidarma*, 4(3), 650–658. <https://doi.org/10.30865/mib.v4i3.2181>
- Tugrul, B., Elfatimi, E., & Eryigit, R. (2022). Convolutional Neural Networks in Detection of Plant Leaf Diseases: A Review. *Agriculture*, 12(8), Article ID: 1192.
<https://doi.org/10.3390/agriculture12081192>
- Upadhyay, A., Chandel, N. S., Singh, K. P., Chakraborty, S. K., Nandede, B. M., Kumar, M., Subeesh, A., Upendar, K., Salem, A., & Elbeltagi, A. (2025). Deep Learning and Computer Vision in Plant Disease Detection: A Comprehensive Review of Techniques, Models, and Trends in Precision Agriculture. *Artificial Intelligence Review*, 58(3), Article ID: 92.
<https://doi.org/10.1007/s10462-024-11100-x>
- Zalvadila, A. (2023). Klasifikasi Penyakit Tanaman Bawang Merah Menggunakan Metode SVM dan CNN. *Jurnal Informatika: Jurnal Pengembangan IT*, 8(3), 255–260.
<https://doi.org/10.30591/jpit.v8i3.5341>
- Żarski, M., Wójcik, B., & Miszczak, J. A. (2021). Krakn: Transfer Learning Framework and Dataset for Infrastructure Thin Crack Detection. *SoftwareX*, 16, Article ID: 100893.
<https://doi.org/10.1016/J.SOFTX.2021.100893>

