

# KLASIFIKASI DAUN TOMAT SEHAT DAN TERSERANG PENYAKIT MENGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)

Rangga Utama Putra<sup>1</sup>, Habib Muhammad Ridwan<sup>2</sup>, Ilham Abiansyah<sup>3</sup>,  
Tinuk Agustin<sup>4</sup>

<sup>1234</sup>Prodi S1 Informatika, STMIK Amikom Surakarta

<sup>1234</sup>Sukoharjo Indonesia

Email: <sup>1</sup>[rangga.10471@mhs.amikomsolo.ic.id](mailto:rangga.10471@mhs.amikomsolo.ic.id),

<sup>2</sup>[habib.10466@mhs.amikomsolo.ic.id](mailto:habib.10466@mhs.amikomsolo.ic.id), <sup>3</sup>[ilham.10453@mhs.amikomsolo.ic.id](mailto:ilham.10453@mhs.amikomsolo.ic.id),

<sup>4</sup>[agustin.amikom@gmail.com](mailto:agustin.amikom@gmail.com)

## Abstract

*Tomato plants (Solanum lycopersicum) are an important agricultural commodity that has high economic value, both domestically and globally. . According to data from FAO, world tomato production will reach more than 180 million tons in 2023, with the main producing countries being China, India and the United States. However, despite increasing tomato production, the threat of plant diseases remains a major problem that impacts crop yields and product quality. To deal with this problem, we classified diseases on tomato leaves. Tomato leaves are one of the factors used to see whether tomato plants are good or not. In this study we used the Convolutional Neural Networks (CNN) method which has proven to be effective in classifying plant disease images. This research compares three CNN models, namely the deep model, the wide model, and the combined wide & deep model. Test results show that the deep model provides the best performance, with the highest accuracy of 100%. The average macro and weighted values for all classes in the deep model show a precision level of 0.99, recall 0.99, and F1-score 0.99, which reflects the consistency and accuracy of the model in classifying each class accurately.*

**Keywords:** Convolutional Neural Network (CNN), Tomato Leaf, Disease Classification, Deep Model

## Abstraksi

*Tanaman tomat (Solanum lycopersicum) merupakan salah satu komoditas pertanian penting yang memiliki nilai ekonomi tinggi, baik secara domestik maupun global. . Menurut data dari FAO, produksi tomat dunia mencapai lebih dari 180 juta ton pada tahun 2023, dengan negara produsen utama seperti Tiongkok, India, dan Amerika Serikat. Namun, meskipun produksi tomat meningkat, ancaman penyakit tanaman tetap menjadi masalah besar yang berdampak pada hasil panen dan kualitas produk. Untuk menangani permasalahan tersebut kami melakukan klasifikasi penyakit pada daun tomat. . Daun tomat menjadi salah satu faktor yang digunakan untuk melihat apakah tanaman tomat itu baik atau tidak. Pada penelitian ini kami menggunakan metode Convolutional Neural Networks (CNN) yang terbukti efektif dalam mengklasifikasikan gambar penyakit tanaman. Penelitian ini membandingkan tiga model CNN, yaitu model deep, model wide, dan model gabungan wide & deep. Hasil pengujian menunjukkan bahwa model deep*

*memberikan performa terbaik, dengan akurasi tertinggi sebesar 100%. Rata-rata nilai macro dan weighted untuk semua kelas pada model deep menunjukkan tingkat presisi 0,99, recall 0,99, dan F1-score 0,99, yang mencerminkan konsistensi dan ketepatan model dalam mengklasifikasikan setiap kelas secara akurat.*

**Kata Kunci:** Convolutional Neural Network (CNN), Daun Tomat, Klasifikasi Penyakit, Model Deep

## 1. PENDAHULUAN

Tanaman tomat (*Solanum lycopersicum*) merupakan salah satu komoditas pertanian penting yang memiliki nilai ekonomi tinggi, baik secara domestik maupun global. Tomat banyak dimanfaatkan dalam industri pangan karena kaya akan nutrisi seperti vitamin C, likopen, dan antioksidan[1]. Menurut data dari FAO, produksi tomat dunia mencapai lebih dari 180 juta ton pada tahun 2023, dengan negara produsen utama seperti Tiongkok, India, dan Amerika Serikat. Namun, meskipun produksi tomat meningkat, ancaman penyakit tanaman tetap menjadi masalah besar yang berdampak pada hasil panen dan kualitas produk.

Salah satu tantangan utama dalam budidaya tomat adalah serangan penyakit pada daun, seperti bercak bakteri (Bacterial Spot) dan layu bakteri (Bacterial Wilt)[2]. Penyakit ini dapat menyebar dengan cepat dan menyebabkan kerusakan besar jika tidak diidentifikasi serta diatasi secara dini. Identifikasi penyakit daun secara manual oleh petani atau ahli seringkali membutuhkan waktu dan keahlian khusus. Selain itu, metode ini rentan terhadap kesalahan, terutama ketika gejala penyakit masih berada pada tahap awal, yang bisa menyebabkan penundaan penanganan.

Di era pertanian modern, penggunaan teknologi berbasis kecerdasan buatan (AI) mulai diterapkan secara luas untuk membantu petani dalam memantau kesehatan tanaman secara lebih efisien. Salah satu pendekatan yang semakin populer adalah penggunaan Convolutional Neural Networks (CNN), sebuah metode deep learning yang dirancang khusus untuk tugas klasifikasi gambar. CNN dapat mengenali pola visual yang kompleks dan terbukti efektif dalam mengklasifikasikan gambar penyakit tanaman[3]. Beberapa penelitian sebelumnya telah menunjukkan keberhasilan penerapan CNN dalam mendeteksi penyakit pada tanaman seperti padi dan jagung, namun penelitian khusus pada daun tomat masih relatif terbatas.

Penelitian ini bertujuan untuk mengembangkan model klasifikasi berbasis CNN yang mampu membedakan daun tomat yang sehat dan yang terkena penyakit. Dataset yang digunakan akan dipreproses melalui beberapa tahapan seperti resizing, normalisasi, dan augmentasi data sebelum dimasukkan ke dalam model CNN. Evaluasi kinerja model dilakukan dengan menggunakan metrik akurasi, precision, dan recall untuk mengetahui seberapa baik model dalam mendeteksi penyakit daun tomat. Dengan pendekatan ini, diharapkan model CNN yang dikembangkan dapat membantu petani dalam mengidentifikasi penyakit daun tomat secara cepat dan akurat, sehingga penanganan dapat dilakukan lebih dini dan kerugian produksi dapat diminimalkan.

## 2. TINJAUAN PUSTAKA

Berbagai penelitian telah dilakukan untuk menganalisis penyakit pada daun tomat menggunakan metode Convolutional Neural Network (CNN). Armin Lawi, dalam penelitiannya, menerapkan enam model CNN untuk klasifikasi penyakit daun tomat. Hasil penelitian ini menunjukkan bahwa model ensemble memberikan akurasi tertinggi sebesar 90,83%, dengan rata-rata nilai precision dan recall berkisar antara 0,8 hingga 1,0[4].

Penelitian lain oleh El Primo Gemilang berhasil mencapai akurasi 90,15% dengan menggunakan dataset yang terdiri dari 12.716 citra daun tomat yang mencakup berbagai jenis penyakit, seperti Bintik Bakteri, Penyakit Busuk Daun, Jamur Daun, Bintik Sasaran, Tungau Laba-laba, Virus Mosaik, Virus Keriting Daun Kuning, Bercak Daun Septoria, serta daun sehat[5].

Selanjutnya, Muhammad Islahfari Wahid dalam penelitiannya menggunakan dataset sebanyak 2.000 citra daun tomat yang terbagi menjadi 10 kelas, dengan setiap kelas terdiri dari 200 citra. Metode yang digunakan adalah Deep Learning dengan algoritma CNN dan arsitektur InceptionV4, yang menghasilkan akurasi 90,00% dalam mengidentifikasi jenis penyakit tanaman tomat[6].

Rendra Soekarta dalam penelitiannya menggunakan dataset yang terdiri dari 10.519 data pelatihan dan 1.100 data validasi, yang mencakup 10 jenis penyakit, termasuk Bacterial Spot, Early Blight, Late Blight, Leaf Mold, Septoria Leaf Spot, Spider Mite, Target Spot, Mosaic Virus, dan Yellow Leaf Virus. Model yang dikembangkan dalam penelitian ini mencapai train accuracy sebesar 98% dan validation accuracy sebesar 82%[7].

Adhitya Jamalludin Bastari melakukan penelitian dengan menggunakan teknologi Deep Learning untuk memperoleh informasi yang lebih mendalam dan akurat tentang pertumbuhan serta kualitas tanaman tomat. Penelitian ini berhasil mencapai akurasi 99% dalam mengklasifikasikan citra daun tomat yang sehat, serta daun yang terinfeksi penyakit seperti jamur Septoria, jamur Fulva, dan Target Spot, menggunakan model Inception V3. Perangkat lunak berbasis desktop yang dikembangkan dalam penelitian ini mampu menampilkan hasil klasifikasi jenis daun secara spesifik[8].


## 3. METODE PENELITIAN

### 3.1. Jenis Penelitian

Jenis penelitian ini menggunakan metode eksperimental untuk mengevaluasi kinerja model *Convolutional Neural Network* (CNN) dalam klasifikasi penyakit daun tomat. Digunakan data citra yang terdiri dari empat kelas, yaitu daun tomat sehat dan daun yang terkena penyakit bakteri. Dataset ini berisi total 400 gambar dan diunduh dari "Tomato Leaf Disease Detection" yang diunduh dari <https://www.kaggle.com/datasets/kaustubhb999/tomatoleaf>. Setiap kelas memiliki 100 gambar yang telah melalui proses pra-pengolahan, termasuk resizing dan augmentasi data. Data tersebut kemudian digunakan untuk membangun model klasifikasi berbasis Convolutional Neural Network (CNN) guna membedakan daun tomat sehat dan yang

terinfeksi. Evaluasi model dilakukan menggunakan metrik akurasi, precision, dan recall untuk mengukur performa klasifikasi.

### 3.2. Alur Penelitian



Gambar 1. Alur Kerja Penelitian

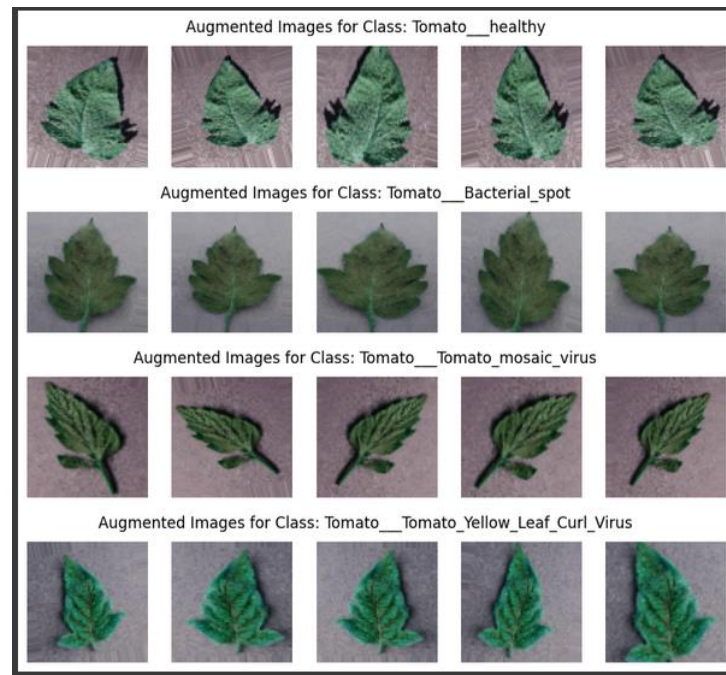
### 3.3. Pengembangan Model CNN

#### 3.3.1. Akusisi dan Deskripsi Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari total 400 gambar yang terbagi secara merata ke dalam empat kelas, yaitu Tomato\_\_healthy yang mencakup daun tomat sehat sebanyak 100 gambar, Tomato\_\_Bacterial\_spot dengan 100 gambar daun yang terinfeksi bercak bakteri, Tomato\_\_Tomato\_mosaic\_virus dengan 100 gambar daun yang terinfeksi virus mosaik tomat, dan Tomato\_\_Tomato\_Yellow\_Leaf\_Curl\_Virus yang mencakup 100 gambar daun yang terinfeksi virus kuning keriting daun tomat. Dataset ini mencerminkan berbagai kondisi daun, baik yang sehat maupun terinfeksi penyakit, sehingga dapat meningkatkan kemampuan model untuk mengenali pola dan menghasilkan generalisasi yang baik dalam proses klasifikasi, yang dapat dilihat pada table 1 sedangkan Gambar 2 menampilkan proses daun setelah melalui tahap augmentasi.

Tabel 1. Pembagian Dataset

DATA	JUMLAH
<i>Tomato_healthy</i>	100
<i>Tomato_Bacterial_spot</i>	100
<i>Tomato_Tomato_mosaic_virus</i>	100
<i>Tomato_Tomato_Yellow_Leaf_Curl_Virus</i>	100



Gambar 2. Hasil proses Augmentasi

### 3.3.2. Pra-pemrosesan Data

Pra-pemrosesan data dilakukan untuk meningkatkan kualitas dan variasi dataset yang digunakan dalam pelatihan model CNN. Tahap ini melibatkan beberapa langkah penting, di antaranya resizing, yaitu mengubah ukuran gambar agar sesuai dengan dimensi input yang dibutuhkan oleh model CNN. Selain itu, dilakukan juga augmentasi data, yang mencakup berbagai teknik seperti rotasi, flipping, scaling, dan translasi. Teknik-teknik ini bertujuan untuk memperkenalkan variasi pada dataset sehingga model dapat lebih baik mengenali pola-pola yang ada dan meningkatkan kemampuan generalisasinya selama proses pelatihan.

### 3.3.3. Pengembangan Model CNN

Model Convolutional Neural Network (CNN) dirancang untuk mengenali pola-pola kompleks seperti bentuk, tekstur, dan warna pada gambar daun tomat. Arsitektur model ini terdiri dari beberapa lapisan utama, yaitu lapisan konvolusi yang berfungsi untuk mengekstraksi fitur visual utama dari gambar, dilanjutkan dengan pooling layer yang bertugas mereduksi dimensi data tanpa kehilangan informasi penting. Pada tahap akhir, fully connected layer digunakan untuk melakukan klasifikasi gambar ke dalam salah satu

dari empat kategori yang telah ditentukan. Model ini dilatih menggunakan parameter pelatihan yang mencakup optimizer Adam, learning rate sebesar 0.001, batch size sebanyak 32, dan jumlah epoch sebanyak 50 untuk memastikan model mampu mempelajari pola dengan optimal.

#### **3.3.4. Pelatihan dan Validasi Model**

Model dilatih menggunakan data latih untuk mempelajari pola-pola yang terdapat dalam data, sementara data validasi digunakan untuk menguji kemampuan generalisasi model terhadap data yang tidak dilibatkan dalam proses pelatihan. Selama pelatihan, metrik *validation accuracy* dicatat pada setiap *epoch* untuk memantau perkembangan kinerja model. Pencatatan ini bertujuan untuk memastikan bahwa model tidak hanya memahami data pelatihan dengan baik, tetapi juga mampu memberikan prediksi yang akurat pada data validasi, sehingga mengurangi risiko *overfitting*.

#### **3.3.5. Evaluasi Model**

Kinerja model dievaluasi menggunakan beberapa metrik untuk memastikan hasil klasifikasi yang akurat dan efektif. *Validation Accuracy* digunakan untuk mengukur persentase prediksi yang benar pada data validasi, memberikan gambaran umum tentang kemampuan model mengenali pola dalam data. Selain itu, *Precision* menilai ketepatan model dalam memprediksi kelas tertentu, di mana nilai *precision* yang tinggi menunjukkan bahwa model jarang salah dalam menentukan suatu kelas. *Recall* mengukur sensitivitas model terhadap instance yang relevan, sehingga mampu menilai seberapa baik model dalam mendeteksi semua contoh dari suatu kelas tertentu. Untuk memberikan keseimbangan antara *precision* dan *recall*, digunakan metrik *F1-Score* yang merupakan rata-rata harmonis dari kedua metrik tersebut. Dengan memanfaatkan keempat metrik ini, analisis performa model menjadi lebih komprehensif, mencerminkan kemampuan model dalam mengklasifikasikan gambar daun tomat secara akurat dan konsisten[9].

## **4. HASIL DAN PEMBAHASAN**

### **4.1. Perbandingan kinerja arsitektur CNN**

Model ini terdiri dari dua lapisan konvolusional yang masing-masing diikuti oleh lapisan max-pooling, sebuah lapisan flatten untuk mengubah peta fitur 2D menjadi 1D, dan dua lapisan dense. Jumlah parameter yang sangat besar pada lapisan dense pertama (1.183.808) disebabkan oleh banyaknya koneksi dari lapisan flatten yang memiliki ukuran besar. Hal ini umum terjadi pada arsitektur CNN yang tidak menggunakan teknik regulasi seperti dropout atau weight decay. Tanpa regulasi, model ini berisiko mengalami *overfitting*, terutama jika dataset yang digunakan relatif kecil yang dapat dilihat pada gambar 3.

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 73, 73, 32)	896
max_pooling2d (MaxPooling2D)	(None, 36, 36, 32)	0
conv2d_1 (Conv2D)	(None, 34, 34, 64)	18,496
max_pooling2d_1 (MaxPooling2D)	(None, 17, 17, 64)	0
flatten (Flatten)	(None, 18496)	0
dense (Dense)	(None, 64)	1,183,808
dense_1 (Dense)	(None, 4)	260

**Gambar 3.** Nilai Parameter pada Model CNN tanpa Regularisasi

Dalam penelitian ini membandingkan tiga model, yaitu model deep, model wide, dan model gabungan wide dan deep. Hasil percobaan dari ketiga model tersebut dapat dilihat pada tabel 2.

**Tabel 2.** Hasil Uji Coba Model

MODEL	ACCURACY	TIME
DEEP	100%	79.8998703956604/s
WIDE	98.75%	50.14100360870361/s
WIDE & DEEP	96.67%	58.945295572280884/s

Model deep dan wide masing-masing menunjukkan hasil yang sangat baik dalam menangkap pola pada dataset, dengan akurasi total mencapai 100% untuk model deep dan 98.75% untuk model wide. Model deep sangat efektif dalam mengidentifikasi pola-pola kompleks dan non-linear yang sulit terprediksi, sementara model wide lebih unggul dalam mengenali pola langsung atau aturan spesifik. Meskipun model gabungan wide & deep menghasilkan akurasi validasi tertinggi 96.67%, hasil ini sedikit lebih rendah dibandingkan model deep dan wide secara individual. Hal ini mengindikasikan bahwa dalam kasus ini, menggunakan model deep atau wide secara terpisah lebih optimal untuk mencapai akurasi prediksi yang tinggi. Model deep dan wide terbukti mampu memberikan performa tinggi baik dalam mengenali pola kompleks maupun pola langsung, menjadikannya pilihan terbaik untuk generalisasi pada data baru atau yang bervariasi. Dengan demikian, kami menggunakan model deep sebagai acuan dalam laporan ini karena model deep mencapai tingkat akurasi tertinggi sebesar 100%, mengungguli model wide dan model gabungan wide & deep.

## 4.2. Model Evaluasi yang digunakan

```
Akurasi: 0.99
Laporan Klasifikasi:
```


	precision	recall	f1-score	support
Tomato__healthy	1.00	1.00	1.00	26
Tomato__Bacterial_spot	1.00	0.94	0.97	18
Tomato__Tomato_mosaic_virus	1.00	1.00	1.00	18
Tomato__Tomato_Yellow_Leaf_Curl_Virus	0.95	1.00	0.97	18
accuracy			0.99	80
macro avg	0.99	0.99	0.99	80
weighted avg	0.99	0.99	0.99	80

**Gambar 4.** Hasil Klasifikasi

Nilai Akurasi Model Deep Pada Gambar 4 menunjukkan bahwa 99% prediksi sesuai dengan data validasi. Berikut hasil evaluasi klasifikasi untuk masing-masing kelas :


- Tomato\_\_healthy: Precision, recall, dan F1-score masing-masing sebesar 1.00 (100%), menunjukkan bahwa semua prediksi model untuk kelas ini benar. Support: 26.
- Tomato\_\_Bacterial\_spot: Precision sebesar 1.00 (100%), recall 0.94 (94%), dan F1-score 0.97 (97%), menunjukkan performa yang baik dalam mendeteksi kelas ini. Support: 18.
- Tomato\_\_Tomato\_mosaic\_virus: Precision, recall, dan F1-score masing-masing sebesar 1.00 (100%), menunjukkan akurasi sempurna dalam klasifikasi kelas ini. Support: 18.
- Tomato\_\_Tomato\_Yellow\_Leaf\_Curl\_Virus: Precision sebesar 0.95 (95%), recall 1.00 (100%), dan F1-score 0.97 (97%), menunjukkan performa yang kuat untuk kelas ini. Support: 18.

Rata-rata macro dan weighted dari seluruh kelas adalah precision 0.99, recall 0.99, dan F1-score 0.99, mengindikasikan performa model yang konsisten tinggi dalam keseluruhan klasifikasi.




**Gambar 5.** Akurasi Model Wide&Deep






Gambar 6. Akurasi Model Wide



Gambar 7. Akurasi Model Deep

Berdasarkan ketiga grafik yang ditampilkan pada Gambar 5, Gambar 6, dan Gambar 7, yang menunjukkan hasil penggunaan tiga model berbeda, grafik loss terbaik diperoleh dengan menggunakan model deep. Grafik ini menampilkan hasil training loss untuk data pelatihan dan pengujian selama 100 epoch. Pada awalnya, loss pengujian dimulai dengan nilai yang cukup tinggi, sekitar 1.4, namun menurun tajam selama 10 epoch pertama, mencerminkan proses pembelajaran awal yang cepat. Loss pada data pelatihan tetap konsisten rendah, menunjukkan bahwa model ini sesuai dengan data pelatihan. Sementara itu, loss pada data pengujian sedikit lebih tinggi dibandingkan loss pelatihan, yang merupakan hal wajar. Secara keseluruhan, loss pengujian tetap cukup rendah, menunjukkan kemampuan generalisasi model yang baik terhadap data pengujian[10].



Gambar 8. Hasil Confusion Matrix

Hasil dari confusion matrix pada gambar 8 di atas menunjukkan bahwa model klasifikasi berhasil mengklasifikasikan empat kelas yang berbeda dengan akurasi tinggi. Keempat kelas tersebut adalah *Tomato\_healthy*, *Tomato\_Bacterial\_spot*, *Tomato\_Tomato\_mosaic\_virus*, dan *Tomato\_Tomato\_Yellow\_Leaf\_Curl\_Virus*. Setiap gambar dalam dataset berhasil diklasifikasikan dengan benar sesuai dengan kelasnya masing-masing, menandakan bahwa model memiliki performa yang sangat baik dalam membedakan antara berbagai penyakit pada daun tomat serta kondisi daun yang sehat. Berikut adalah interpretasi singkat dari hasil tersebut :

- Model memprediksi 26 gambar sebagai *Tomato\_healthy*, yang semuanya benar (True Positif).
- Model memprediksi 18 gambar sebagai *Tomato\_Bacterial\_spot*, yang semuanya benar (True Positif).
- Model memprediksi 18 gambar sebagai *Tomato\_Tomato\_mosaic\_virus*, yang semuanya benar (True Positif).
- Model memprediksi 18 gambar sebagai *Tomato\_Tomato\_Yellow\_Leaf\_Curl\_Virus*, yang semuanya benar (True Positif).

#### 4.3. Diskusi

Menurut penelitian ini, pencapaian akurasi sebesar 100% disebabkan oleh beberapa faktor. Salah satunya adalah kualitas dataset yang jelas dan konsisten dengan sedikit noise atau variasi ekstrem, sehingga memungkinkan model deep untuk mengenali

pola dengan lebih mudah. Dataset dengan gambar yang seragam dalam hal pencahayaan, sudut pandang, dan resolusi cenderung meningkatkan akurasi model secara signifikan. Selain itu, arsitektur model deep yang kompleks memungkinkan identifikasi pola visual secara lebih mendalam, sehingga model dapat mengenali detail-detail penting pada daun tomat dengan lebih akurat. Dengan jumlah epoch yang cukup serta parameter yang diatur secara optimal, model mampu belajar secara mendalam tanpa mengalami overfitting atau underfitting.

Untuk memberikan gambaran yang lebih luas mengenai pencapaian model dalam penelitian ini, berikut adalah tabel perbandingan penelitian terdahulu yang menunjukkan performa akurasi dari berbagai pendekatan dan faktor yang mempengaruhi hasilnya, dapat dilihat pada table 3.

**Tabel 3.** Perbandingan Penelitian Terdahulu

Author	Metode Cnn	Jumlah Kelas	Jumah Dataset	Val_Accuracy
Armi Lawi	<i>Ensemble</i>	6	1.200	90.83%
El Primo Gemilang	<i>Lenet-5</i>	10	18.260	90.15%
Muhammad Islahfari Wahid	<i>Inceptionv4</i>	10	2.000	90.15%
Rendra Soekarta	<i>Vgg 16</i>	10	10.519	82.00%
Adithya Jamaludin Bastari	<i>Inceptionv3</i>	4	5.632	99.00%

## 5. KESIMPULAN

Berdasarkan hasil analisis dan pembahasan yang telah dilakukan, dapat disimpulkan bahwa model klasifikasi yang dikembangkan memiliki performa yang sangat baik dalam membedakan empat kategori kondisi daun tomat, yaitu *Tomato\_healthy*, *Tomato\_Bacterial\_spot*, *Tomato\_Tomato\_mosaic\_virus*, dan *Tomato\_Tomato\_Yellow\_Leaf\_Curl\_Virus*. Model ini menunjukkan kemampuan yang tinggi dalam mengklasifikasikan gambar sesuai dengan kelas yang benar, sehingga mampu membedakan dengan tepat antara kondisi daun tomat yang sehat dan berbagai penyakit yang dapat menyerangnya.

Dari ketiga model yang diuji, yaitu model deep, model wide, dan model gabungan (wide & deep), model deep terbukti memberikan hasil akurasi tertinggi, yaitu mencapai 100%. Dengan akurasi setinggi ini, model deep dipilih sebagai model yang paling sesuai karena memiliki tingkat presisi dan keandalan yang sangat baik dalam identifikasi penyakit pada daun tomat. Hasil ini menunjukkan bahwa model deep sangat berpotensi untuk diterapkan dalam sistem identifikasi penyakit tanaman secara otomatis, yang dapat menjadi alat bantu yang efisien dalam mendukung pertanian modern melalui teknologi berbasis kecerdasan buatan.

## DAFTAR PUSTAKA

- [1] T. Pipit Mulyah, Dyah Aminatun, Sukma Septian Nasution, Tommy Hastomo, Setiana Sri Wahyuni Sitepu, “濟無No Title No Title No Title,” *J. GEEJ*, vol. 7, no. 2, pp. 214–224, 2020.
- [2] Y. Devianto, S. Dwiasnati, B. Sukowo, A. Fauzi, and K. A. Baihaqi, “Penerapan Technique for Order Performance by Similarity to Ideal Solution (TOPSIS) untuk Mendiagnosa Penyakit Bercak Daun Cabai,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 3, no. 2, pp. 136–142, 2023, doi: 10.57152/malcom.v3i2.850.
- [3] Prinzky and C. Lubis, “Klasifikasi Buah Segar Dan Busuk Menggunakan Convolutional Neural Network Berbasis Android,” *J. Ilmu Komput. dan Sist. Inf.*, vol. 10, no. 2, pp. 10823–10827, 2022, doi: 10.24912/jiksi.v10i2.22551.
- [4] A. Lawi, N. S. Intizhami, R. Mukhtarom, and S. Amir, “Klasifikasi Penyakit Citra Daun Tanaman Tomat Dengan Ensemble Convolutional Neural Network,” *Sntei*, pp. 207–212, 2022.
- [5] E. P. Gemilang and C. Lubis, “Klasifikasi Jenis Penyakit Pada Daun Tomat Dengan Menggunakan Convolutional Neural Network,” *J. Ilmu Komput. dan Sist. Inf.*, vol. 10, no. 1, 2022, doi: 10.24912/jiksi.v10i1.17839.
- [6] M. I. Wahid, S. A. Mustamin, and D. A. Lawi, “Identifikasi Dan Klasifikasi Citra Penyakit Daun Tomat Menggunakan Arsitektur Inception V4,” *onferensi Nas. Ilmu Komput.*, vol. 5, no. 2019, pp. 257–264, 2021.
- [7] R. Soekarta, N. Nurdjan, and A. Syah, “Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN),” *Insect (Informatics Secur. J. Tek. Inform.*, vol. 8, no. 2, pp. 143–151, 2023, doi: 10.33506/insect.v8i2.2356.
- [8] A. J. Bastari and A. Cherid, “Klasifikasi Penyakit Tanaman Tomat Menggunakan Convolutional Neural Network dan Implementasi Model H5 Pada Aplikasi Desktop,” *Simkom*, vol. 8, no. 2, pp. 199–207, 2023, doi: 10.51717/simkom.v8i2.194.
- [9] W. A. Firmansyach, U. Hayati, and Y. Arie Wijaya, “Analisa Terjadinya Overfitting Dan Underfitting Pada Algoritma Naive Bayes Dan Decision Tree Dengan Teknik Cross Validation,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 7, no. 1, pp. 262–269, 2023,

doi: 10.36040/jati.v7i1.6329.

- [10] I. Artikel, "Jurnal SENOPATI," pp. 28–41, 2024.