

## PENERAPAN CONVOLUTIONAL NEURAL NETWORK (CNN) UNTUK KLASIFIKASI PENYAKIT DAUN TOMAT

Wahyuni Fitratul Zalmi<sup>1\*</sup>, Pujo Hari Saputro<sup>2</sup>, Jonathan Sitanggang<sup>3</sup>, Kevin Leatemia<sup>4</sup>

Prodi Teknik Informatika, Fakultas Teknik, Universitas Sam Ratulangi Manado

Jl. Kampus UNSRAT Bahu, Kecamatan Malalayang 95115, Kota Manado, Sulawesi Utara, Indonesia

email: [wahyuni.fitratul.zalmi@unsrat.ac.id](mailto:wahyuni.fitratul.zalmi@unsrat.ac.id)<sup>1\*</sup>, [pujoharisaputro@unsrat.ac.id](mailto:pujoharisaputro@unsrat.ac.id)<sup>2</sup>,

[jonathansitanggang026@student.unsrat.ac.id](mailto:jonathansitanggang026@student.unsrat.ac.id)<sup>3</sup>, [kevinleatemia026@student.unsrat.ac.id](mailto:kevinleatemia026@student.unsrat.ac.id)<sup>4</sup>

**Abstrak.** Tanaman tomat sering menghadapi ancaman penyakit daun yang secara signifikan menurunkan produktivitas dan kualitas hasil panen. Identifikasi dini dan tepat terhadap penyakit-penyakit ini menjadi krusial untuk mencegah kerugian ekonomi yang lebih masif. Penelitian ini mengusulkan pendekatan modern berbasis kecerdasan buatan menggunakan arsitektur *Convolutional Neural Network* (CNN) untuk mengenali dan mengklasifikasikan penyakit pada daun tomat secara otomatis. Dataset penelitian terdiri dari berbagai gambar daun tomat dengan beragam kondisi penyakit, yang kemudian diperkaya menggunakan teknik augmentasi data untuk meningkatkan variabilitas dan kualitas dataset. Konstruksi model CNN yang diimplementasikan terdiri dari serangkaian lapisan konvolusi dan *max-pooling* untuk ekstraksi fitur, diikuti dengan lapisan dense untuk proses klasifikasi ke dalam 10 kategori penyakit yang berbeda. Hasil evaluasi menunjukkan performa model yang sangat memuaskan dengan tingkat akurasi mencapai 95.84% pada dataset validasi, disertai kemampuan diskriminatif yang baik dalam membedakan berbagai jenis penyakit. Analisis melalui matriks konfusi (*confusion matrix*) memperlihatkan konsistensi performa klasifikasi model, meskipun terdapat beberapa kesalahan klasifikasi pada kategori tertentu dengan kemiripan visual. Sistem klasifikasi berbasis CNN ini menawarkan solusi yang efektif dan efisien bagi petani dan peneliti dalam melakukan deteksi penyakit daun tomat, sehingga memungkinkan penanganan yang lebih cepat dan tepat untuk memaksimalkan hasil produksi.

**Kata Kunci:** Penyakit\_Daun, Deep\_Learning, Convolutional\_Neural\_Network, Pertanian

### 1 Pendahuluan

Tomat (*Solanum lycopersicum*) merupakan komoditas hortikultura dengan nilai ekonomis tinggi yang dibudidayakan secara ekstensif di berbagai belahan dunia. Selain menjadi sumber nutrisi penting yang kaya akan vitamin C dan likopen, tomat juga menjadi bahan baku utama dalam berbagai industri makanan olahan[1]. Namun, produktivitas tanaman tomat seringkali terganggu oleh serangan berbagai patogen yang menyebabkan penyakit pada daun, seperti *Septoria leaf spot*, *yellow leaf curl*, dan *early blight*. Serangan penyakit ini tidak hanya merusak kondisi daun tetapi juga berdampak sangat signifikan terhadap kuantitas dan kualitas hasil panen, yang berujung pada kerugian ekonomi substansial bagi petani[2]. Pada kasus-kasus tertentu, kerugian akibat serangan penyakit dapat mencapai hingga 50% dari total potensi hasil panen, menegaskan pentingnya pengembangan metode deteksi dini yang efektif dan akurat.

Identifikasi awal penyakit pada tanaman tomat menjadi sangat vital untuk mencegah penyebaran yang lebih luas serta memungkinkan implementasi strategi pengendalian yang lebih efektif dan ramah lingkungan[3]. Pendekatan konvensional dalam identifikasi penyakit daun tomat umumnya mengandalkan inspeksi visual oleh pakar agronomi, yang memiliki keterbatasan signifikan terkait efisiensi waktu, biaya yang relatif tinggi, serta ketergantungan pada ketersediaan tenaga ahli. Selain itu, metode inspeksi visual rentan terhadap inkonsistensi dan kesalahan penilaian manusia. Kondisi ini menciptakan kebutuhan akan solusi alternatif yang lebih cepat, presisi, dan efisien untuk mendeteksi penyakit pada tahap awal perkembangannya[4].

Kemajuan pesat dalam bidang teknologi komputasi, khususnya *deep learning*, membuka peluang besar untuk pengembangan solusi yang lebih superior dalam mengatasi permasalahan ini. *Convolutional Neural Network* (CNN) hadir sebagai arsitektur pembelajaran mesin yang sangat potensial untuk tugas pemrosesan citra dan klasifikasi, terutama dalam konteks deteksi penyakit tanaman[5]. CNN memiliki kapabilitas untuk mengekstraksi berbagai fitur esensial dari citra, seperti tekstur, warna, dan pola karakteristik, yang kemudian dapat dimanfaatkan untuk melakukan klasifikasi penyakit dengan tingkat akurasi yang tinggi[6]. Dalam penelitian ini, kami mengembangkan dan mengimplementasikan model CNN untuk mengklasifikasikan citra daun tomat ke dalam beberapa kategori kondisi penyakit, termasuk daun sehat, *Septoria leaf spot*, *yellow leaf curl*, dan *early blight*.

ISSN: 2655-139X (ONLINE)

ISSN: 0216-4221 (PRINT)

Dataset yang digunakan dalam penelitian ini mencakup berbagai citra daun tomat dengan beragam kondisi penyakit. Koleksi citra tersebut diperoleh dari berbagai sumber, mencakup sampel dari lapangan dan laboratorium, dengan variasi resolusi untuk memastikan generalisasi model. Untuk mengoptimalkan performa model, teknik augmentasi data diterapkan untuk memperkaya variasi data pelatihan[7]. Metode augmentasi yang diimplementasikan meliputi rotasi, pembalikan (flipping), penskalaan (scaling), dan penambahan derau (noise), yang bertujuan untuk mengurangi potensi overfitting dan meningkatkan kemampuan model dalam mengenali pola yang lebih beragam. Augmentasi data merupakan strategi yang terbukti efektif untuk meningkatkan dimensi dataset dan keragaman sampel, sehingga model dapat beradaptasi lebih baik dalam menghadapi berbagai kondisi nyata di lapangan[8].

Arsitektur model CNN yang dikonstruksi terdiri dari beberapa lapisan konvolusi dan *max-pooling* untuk mengekstraksi fitur dari citra, diikuti dengan lapisan dense untuk proses klasifikasi citra ke dalam kategori penyakit yang sesuai. Struktur model dirancang dengan mempertimbangkan keseimbangan optimal antara akurasi dan kompleksitas komputasi, sehingga sesuai untuk implementasi dalam skenario aplikasi praktis[9] Model dilatih menggunakan *optimizer* Adam dengan learning rate dinamis yang menurun secara bertahap dan fungsi kerugian *categorical cross-entropy*. Parameter-parameter model, seperti jumlah lapisan konvolusi dan dimensi filter, dioptimalkan melalui proses *fine-tuning* untuk memaksimalkan performa klasifikasi[10].

Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi penyakit daun tomat yang akurat dan efisien berbasis teknologi *deep learning*. Dengan demikian, diharapkan sistem ini dapat menjadi instrumen bantu yang efektif bagi petani dan peneliti dalam melakukan deteksi dini penyakit dan mengoptimalkan hasil panen[11]. Selain itu, sistem ini juga berpotensi mendukung praktik pengelolaan tanaman yang lebih berkelanjutan dan berwawasan lingkungan. Implementasi model CNN diharapkan dapat mengurangi ketergantungan pada penggunaan pestisida kimia secara berlebihan dan meminimalkan dampak negatif terhadap ekosistem[12].

## 2 Metode Penelitian

### 2.1 Penyakit Daun Tomat

Penyakit pada daun tomat merepresentasikan salah satu tantangan utama dalam budidaya tanaman ini yang secara langsung berpengaruh terhadap produktivitas dan kualitas produksi. Tanaman tomat (*Solanum lycopersicum*) merupakan salah satu komoditas pertanian dengan signifikansi ekonomi tertinggi di dunia, dengan volume produksi yang sangat besar dan distribusi geografis yang ekstensif. Namun, tanaman ini memiliki kerentanan tinggi terhadap berbagai patogen yang menyebabkan penyakit pada daun, seperti *Septoria leaf spot*, *yellow leaf curl*, dan *early blight*[13]. Serangan penyakit ini tidak hanya menurunkan kualitas fotosintesis pada daun tetapi juga berdampak signifikan pada kuantitas dan kualitas hasil panen, yang berujung pada kerugian ekonomi substansial bagi petani[2]. Dalam beberapa kasus ekstrem, kerugian akibat serangan penyakit dapat mencapai hingga 50% dari total potensi hasil panen, menegaskan urgensi pengembangan metode deteksi dini yang efektif dan akurat.

### 2.2 Deep Learning

Kemajuan signifikan dalam teknologi komputasi, khususnya di bidang *deep learning*, telah membuka jalan bagi pendekatan baru yang lebih efisien, cepat, dan akurat dalam mendeteksi penyakit tanaman. Salah satu metode yang menonjol dalam perkembangan ini adalah *Convolutional Neural Networks* (CNN), sebuah arsitektur *deep learning* yang terbukti unggul [14] dalam tugas-tugas pengolahan dan klasifikasi citra, menjadikannya sangat sesuai untuk digunakan dalam sistem identifikasi penyakit tanaman secara otomatis [14]. CNN memiliki kemampuan untuk mengekstraksi berbagai fitur penting dari citra, seperti pola visual, tekstur permukaan, gradasi warna, dan karakteristik lainnya yang khas dari setiap jenis penyakit. Fitur-fitur ini kemudian digunakan sebagai dasar untuk melakukan klasifikasi kondisi daun tanaman dengan akurasi tinggi. Dalam penelitian ini, kami merancang serta mengimplementasikan model CNN untuk mengklasifikasikan gambar daun tomat ke dalam beberapa kategori kondisi, termasuk daun yang sehat, *septoria leaf spot*, *yellow leaf curl*, serta *early blight*, guna mendukung deteksi dini dan pengambilan keputusan yang lebih tepat dalam pengelolaan tanaman.

### 2.3 Convolutional Neural Network (CNN)

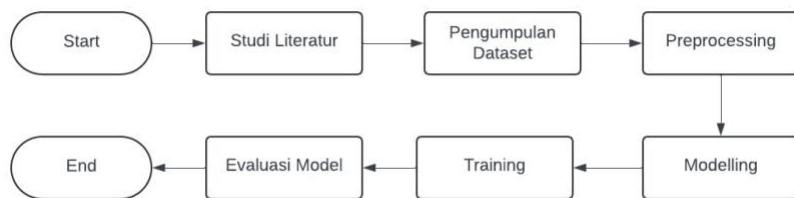
Convolutional Neural Network (CNN) merepresentasikan arsitektur pembelajaran mesin yang sangat efektif untuk tugas pemrosesan citra dan klasifikasi, terutama dalam konteks deteksi penyakit tanaman[15]. Model CNN yang diimplementasikan terdiri dari serangkaian lapisan konvolusi dan *max-pooling* untuk ekstraksi fitur dari citra, diikuti dengan lapisan *dense* untuk proses klasifikasi citra ke dalam kategori penyakit yang sesuai. Struktur model dirancang dengan mempertimbangkan keseimbangan optimal antara akurasi dan kompleksitas komputasi, sehingga sesuai untuk implementasi dalam skenario aplikasi praktis. Model dilatih menggunakan *optimizer* Adam dengan learning rate dinamis yang menurun secara bertahap dan fungsi kerugian *categorical cross-entropy*. Parameter-parameter model, seperti jumlah lapisan konvolusi dan dimensi filter, dioptimalkan melalui proses *fine-tuning* untuk memaksimalkan performa klasifikasi.

### 2.4 Aplikasi Pertanian

Pemanfaatan teknologi *deep learning*, khususnya *Convolutional Neural Network* (CNN), dalam sektor pertanian telah memperlihatkan potensi signifikan dalam meningkatkan efektivitas serta ketepatan dalam proses identifikasi penyakit pada tanaman. Melalui penerapan model CNN, diharapkan terjadi penurunan ketergantungan terhadap penggunaan pestisida berbahaya kimia, yang pada gilirannya dapat mengurangi dampak buruk terhadap keseimbangan ekosistem[16]. Teknologi ini memungkinkan pengembangan sistem deteksi penyakit tanaman yang dapat diintegrasikan ke dalam aplikasi atau perangkat digital yang mudah digunakan, sehingga memberikan kemudahan bagi petani maupun peneliti dalam melakukan deteksi penyakit sejak dini serta mendukung upaya peningkatan produktivitas pertanian. Meski demikian, penerapan teknologi ini secara nyata di lapangan masih menghadapi sejumlah kendala, di antaranya adalah kebutuhan terhadap pemahaman teknis yang cukup dalam bidang *deep learning* serta biaya investasi yang tidak sedikit untuk membangun dan mempertahankan sistem yang handal.

### 2.5 Alur Penelitian

Investigasi ilmiah ini mengadopsi pendekatan metodologis yang terstruktur untuk mengembangkan dan mengevaluasi model *Convolutional Neural Network* (CNN) dalam mengidentifikasi penyakit pada daun tomat. Gambar 1 mengilustrasikan diagram alur dari enam tahapan utama yang diimplementasikan dalam penelitian ini.



**Gambar. 1.** Alur penelitian

### 2.6 Studi Literatur

Langkah inisial dalam penelitian ini adalah pelaksanaan studi literatur komprehensif. Aktivitas ini ditujukan untuk memperoleh pemahaman mendalam tentang konteks penelitian dan mengidentifikasi permasalahan utama yang menjadi fokus investigasi, yaitu deteksi penyakit pada daun tomat menggunakan pendekatan *deep learning*. Pada fase ini, peneliti juga mengumpulkan informasi tentang metodologi yang telah diimplementasikan dalam studi-studi terdahulu, seperti penerapan *Convolutional Neural Network* (CNN) dan teknik augmentasi data, serta mengidentifikasi celah penelitian atau aspek yang belum tereksploras dalam literatur sebelumnya[17] [18]. Hasil dari studi literatur ini dijadikan sebagai fondasi konseptual untuk menentukan arsitektur model CNN yang akan dikembangkan dan kriteria spesifikasi dataset yang dibutuhkan, seperti klasifikasi penyakit dan resolusi citra.

### 2.7 Pengumpulan Dataset

Setelah studi literatur selesai dilaksanakan, penelitian berlanjut ke tahap akuisisi dataset. Pada fase ini, koleksi data yang diperlukan dihimpun dari sumber-sumber relevan, terutama dari platform repository data Kaggle. Dataset yang dikumpulkan diverifikasi untuk memastikan kesesuaiannya dengan kriteria yang telah ditetapkan berdasarkan hasil studi literatur, seperti variasi klasifikasi penyakit yang memadai dan kualitas citra yang optimal[19]. Dataset yang telah terkumpul kemudian dipartisi menjadi tiga subset utama: *Train Set* (70% dari total dataset), yang digunakan untuk proses pelatihan model CNN; *Validation Set* (15% dari total dataset), yang dimanfaatkan untuk validasi performa model selama proses pelatihan; dan *Test Set* (15% dari total dataset), yang digunakan untuk evaluasi komprehensif performa model setelah proses pelatihan selesai. Strategi partisi ini diimplementasikan untuk memastikan bahwa model yang dikembangkan dapat dilatih, divalidasi, dan diuji secara efektif.

## 2.8 Preprocessing Data

Setelah dataset terpartisi, dilaksanakan *preprocessing* data untuk meningkatkan kualitas dan diversitas dataset. Teknik-teknik yang diimplementasikan dalam fase *preprocessing* meliputi *rescaling*, *rotation*, *width shift*, *height shift*, *shear*, *zoom*, dan *horizontal flip*. Metode-metode ini diaplikasikan untuk memastikan bahwa model memiliki kapabilitas generalisasi yang optimal terhadap berbagai variasi kondisi citra yang mungkin ditemui dalam skenario aplikasi *real-world*[20].

## 2.9 Modeling Menggunakan CNN

Berdasarkan hasil analisis literatur, penelitian memasuki fase pengembangan model CNN. Arsitektur model CNN yang diimplementasikan terdiri dari lapisan konvolusi untuk ekstraksi fitur dari citra, lapisan *max-pooling* untuk reduksi dimensi citra, lapisan *flatten* untuk transformasi data 3D menjadi 1D, lapisan *dense* untuk klasifikasi citra ke dalam kategori penyakit yang sesuai, dan *dropout* untuk mitigasi *overfitting* [21]. Model dikompilasi dengan *optimizer* Adam, fungsi kerugian *categorical cross-entropy*, dan metrik akurasi untuk monitoring performa selama pelatihan. Struktur model CNN yang diimplementasikan dapat dilihat pada Tabel 1.

**Tabel 1.** Tabel Model *Sequential CNN*

Layer	Output Shape	Parameter
<b>conv2D (Conv2D)</b>	(None, 222, 222, 32)	896
<b>max_pooling2D (MaxPooling2D)</b>	(None, 111, 111, 32)	0
<b>conv2d_1 (Conv2D)</b>	(None, 109, 109, 64)	18,496
<b>max_pooling2d_1 (MaxPooling2D)</b>	(None, 54, 54, 64)	0
<b>conv2d_2 (Conv2D)</b>	(None, 52, 52, 128)	73,856
<b>max_pooling2d_2 (MaxPooling2D)</b>	(None, 26, 26, 128)	0
<b>flatten (Flatten)</b>	(None, 86528)	0
<b>dense (Dense)</b>	(None, 512)	44,302,848
<b>dropout (Dropout)</b>	(None, 512)	0
<b>dense_1 (Dense)</b>	(None, 10)	5,130

## 2.10 Training

Setelah struktur model terdefinisi, dilaksanakan proses pelatihan model menggunakan data train dengan *batch size* 32 dan jumlah *epoch* 30. Selama proses pelatihan, model juga divalidasi menggunakan data *validation* untuk monitoring performa dan pencegahan *overfitting*[8]. Teknik *early stopping* diimplementasikan untuk terminasi otomatis pelatihan jika nilai kerugian validasi tidak menunjukkan penurunan signifikan dalam lima *epoch* berturut-turut.

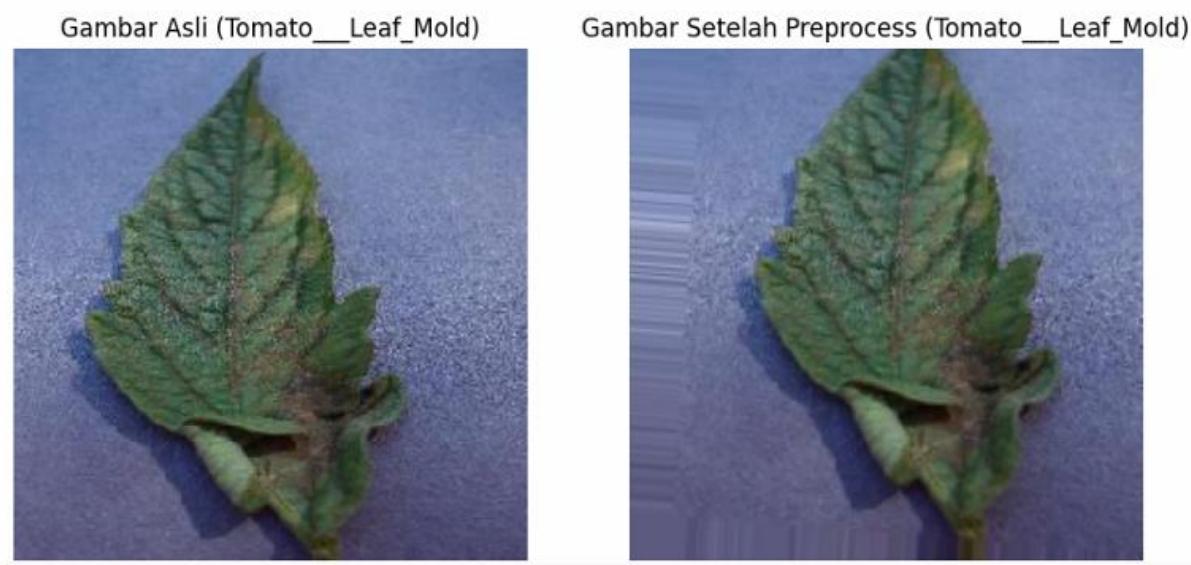
## 2.11 Evaluasi Model

Setelah proses pelatihan selesai, dilaksanakan evaluasi komprehensif model menggunakan data tes untuk menilai performa model secara holistik. Evaluasi mencakup pengukuran akurasi, nilai kerugian, dan konstruksi matriks konfusi untuk analisis mendalam terhadap kinerja klasifikasi model. Hasil evaluasi ini selanjutnya dibandingkan dengan studi-studi sebelumnya yang teridentifikasi dalam fase studi literatur.

## 3 Hasil dan Pembahasan

### 3.1 Hasil Preprocessing

Proses *preprocessing* data menghasilkan tiga subset data yang siap digunakan untuk pelatihan, validasi, dan pengujian model: *data train* (70%), *data validation* (15%), dan *data test* (15%). Partisi dataset dilakukan secara stratifikasi, yaitu dengan mempertahankan proporsi dari setiap kelas citra untuk memastikan distribusi yang seimbang pada setiap subset. Seluruh citra dalam ketiga subset tersebut telah melalui proses normalisasi piksel, di mana nilai intensitas piksel distandarisasi ke rentang [0, 1]. Selain itu, *data train* juga telah diperkaya melalui proses augmentasi data, yang menciptakan variasi tambahan dari citra asli untuk meningkatkan generalisasi model selama pelatihan. Dengan demikian, data yang dihasilkan dari tahap *preprocessing* ini memiliki karakteristik struktural dan kualitas yang optimal sebagai *input* bagi model klasifikasi citra. Visualisasi hasil *preprocessing* data dapat dilihat pada Gambar 2.



Gambar. 2. Perbandingan Sebelum dan Sesudah *Preprocessing*

### 3.2 Hasil Training

Penelitian ini berhasil mengembangkan model *Convolutional Neural Network* (CNN) untuk identifikasi penyakit pada daun tomat dengan tingkat akurasi yang sangat memuaskan. Model yang diimplementasikan mencapai akurasi sekitar 95.84% pada *dataset validation*, dengan nilai kerugian (*loss*) yang relatif rendah. Hal ini mengindikasikan bahwa model memiliki kapabilitas yang sangat baik dalam mengklasifikasikan citra daun tomat ke dalam kategori penyakit yang tepat. Nilai akurasi ini juga menunjukkan bahwa model telah berhasil melakukan generalisasi dari data pelatihan ke data yang belum pernah diproses sebelumnya. Tabel 2 menampilkan metrik akurasi model pada 10 *epoch* terakhir dari total 30 *epoch* yang dijalankan.

Tabel 2. Akurasi Model

epoch	train_accuracy	train_loss	val_accuracy	val_loss
...	...	...	...	...
epoch 21/30	0.9041	0.2832	0.935	0.1867
epoch 22/30	0.905	0.2771	0.9198	0.2328
epoch 23/30	0.9018	0.2873	0.9393	0.1809
epoch 24/30	0.8975	0.2889	0.9177	0.2212
epoch 25/30	0.904	0.2963	0.9523	0.14
epoch 26/30	0.8926	0.3207	0.9532	0.142
epoch 27/30	0.9213	0.2388	0.9371	0.1785
epoch 28/30	0.9186	0.232	0.9555	0.1381
epoch 29/30	0.9282	0.2074	0.942	0.1584
epoch 30/30	0.9103	0.2637	0.9532	0.1395

Berdasarkan Gambar 3, terlihat bahwa performa model mengalami peningkatan bertahap seiring bertambahnya jumlah *epoch*. Akurasi model menunjukkan tren naik yang konsisten, sementara nilai *loss* atau kerugian justru terus menurun. Hal ini mengindikasikan bahwa model mampu mengenali dan mempelajari pola-pola signifikan dari data pelatihan secara efektif. Puncak performa tercapai pada *epoch* ke-30, di mana akurasi tertinggi berhasil diraih. Pada titik ini, tidak ditemukan indikasi *overfitting* yang berarti, karena selisih antara akurasi pelatihan dan validasi tetap kecil dan dalam batas toleransi yang dapat diterima. Fakta ini mengisyaratkan bahwa model memiliki kemampuan generalisasi yang sangat baik terhadap data yang sebelumnya tidak dikenal. Lebih lanjut, bentuk kurva pelatihan menggambarkan bahwa model cukup tangguh dalam menghadapi potensi *overfitting*. Stabilitas perbedaan antara akurasi pelatihan dan validasi menjadi bukti bahwa model tidak hanya unggul pada data latih, tetapi juga mampu mempertahankan kinerjanya saat dihadapkan pada data validasi. Dengan demikian, model dapat diandalkan dan layak diterapkan dalam sistem otomatis untuk mendeteksi penyakit pada daun tomat. Selain itu, peningkatan akurasi yang cepat pada fase awal pelatihan, yang kemudian melambat mendekati akhir proses pelatihan, menandakan bahwa model telah mencapai fase konvergensi optimal. Hal ini menunjukkan bahwa parameter-parameter dalam model telah mengalami penyetelan yang efisien, sehingga tidak diperlukan perubahan besar pada arsitektur atau strategi pelatihan. Keseluruhan hasil ini menunjukkan bahwa model memiliki kapabilitas tinggi dalam mengidentifikasi penyakit daun tomat secara akurat dan konsisten.



Gambar. 3. Kurva Training dan Validasi

### 3.3 Hasil Model CNN Yang Telah Dikembangkan

Gambar 4 mengilustrasikan bahwa model CNN yang telah dikembangkan menunjukkan performa yang sangat memuaskan dengan hanya satu kesalahan klasifikasi, yang kemungkinan disebabkan oleh kemiripan visual antar

ISSN: 2655-139X (ONLINE)

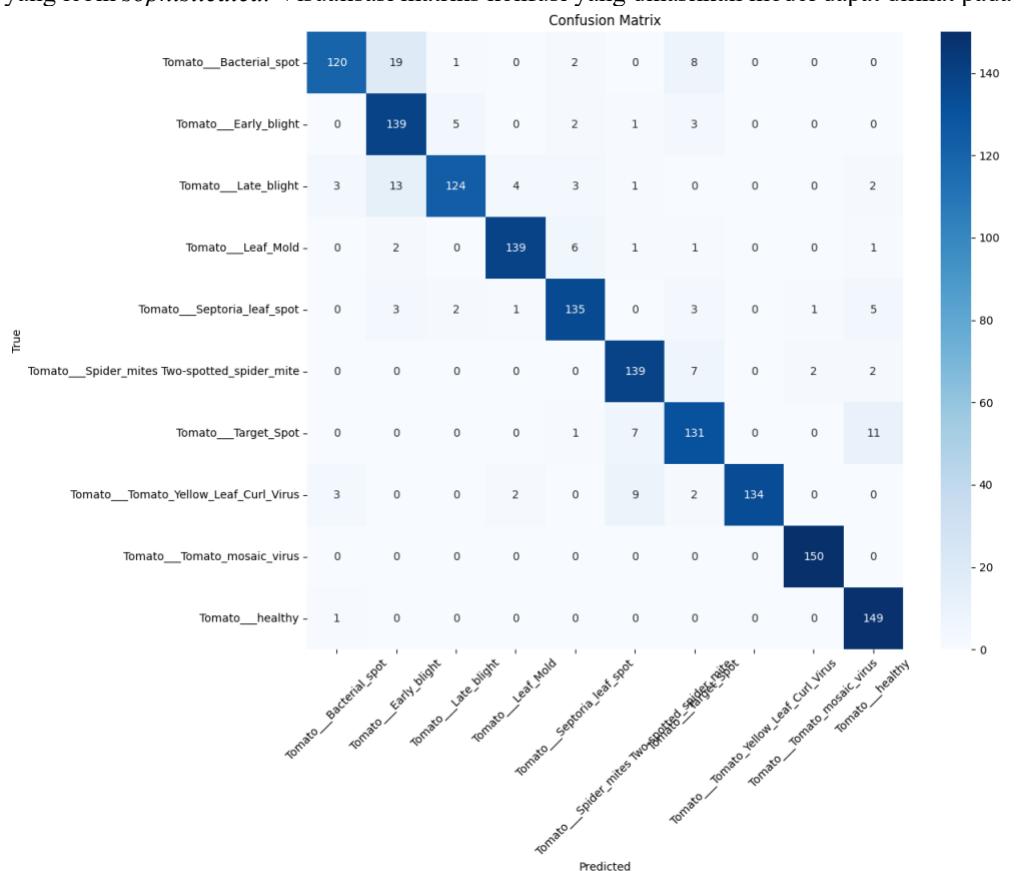
ISSN: 0216-4221 (PRINT)

kategori penyakit. Hal ini mengindikasikan bahwa model CNN yang diimplementasikan memang efektif, namun tetap memiliki limitasi dalam membedakan penyakit dengan karakteristik visual yang sangat mirip. Tantangan ini dapat diatasi melalui penambahan data, implementasi teknik augmentasi yang lebih canggih, atau penggunaan arsitektur *transfer learning* pada penelitian selanjutnya.



**Gambar 4.** Hasil Prediksi Model CNN

Matriks konfusi (*confusion matrix*) menunjukkan bahwa model memiliki konsistensi performa yang baik dalam mengklasifikasikan berbagai jenis penyakit. Namun, terdapat beberapa kesalahan klasifikasi pada kategori tertentu, yang kemungkinan disebabkan oleh kemiripan karakteristik visual antara penyakit tersebut. Sebagai contoh, penyakit *Early Blight* dan *Bacterial Spot* kemungkinan memiliki manifestasi gejala yang mirip secara visual, sehingga model mengalami kesulitan dalam diferensiasi keduanya. Kesalahan klasifikasi ini merupakan informasi yang sangat berharga untuk analisis lanjutan, karena dapat memberikan *insight* tentang limitasi model dan area spesifik yang memerlukan penyempurnaan. Dengan memahami pola kesalahan yang terjadi, peneliti dapat merumuskan strategi untuk meningkatkan akurasi model, seperti memperbanyak sampel data pelatihan untuk kategori yang sering mengalami kesalahan klasifikasi atau mengimplementasikan teknik augmentasi data yang lebih *sophisticated*. Visualisasi matriks konfusi yang dihasilkan model dapat dilihat pada Gambar 5.



**Gambar. 5.** Confusion matrix

### 3.4 Laporan Klasifikasi

Berdasarkan hasil yang ditampilkan dalam laporan klasifikasi, model menunjukkan kinerja yang sangat memuaskan dengan capaian nilai presisi, *recall*, dan *F1-score* yang tinggi di sebagian besar kelas penyakit daun tomat. Capaian ini menandakan bahwa model tidak hanya memiliki tingkat akurasi yang baik dalam mengidentifikasi gambar, tetapi juga menunjukkan keandalan yang konsisten, bahkan saat menghadapi kategori penyakit yang jarang muncul atau sulit dikenali. Tingginya nilai presisi menandakan bahwa ketika model mengklasifikasikan sebuah citra ke dalam suatu kelas penyakit tertentu, kemungkinan prediksi tersebut benar sangat besar. Di sisi lain, *recall* yang tinggi menunjukkan bahwa model mampu mengenali sebagian besar contoh penyakit yang terdapat dalam dataset, tanpa melewatkannya banyak kasus yang relevan. Adapun nilai *F1-score* yang tinggi sebagai gabungan antara presisi dan *recall* menunjukkan bahwa model mampu menjaga keseimbangan antara kemampuan mendeteksi kasus dan akurasi prediksi. Dengan demikian, model tidak hanya unggul dalam satu metrik saja, melainkan menyeluruh dalam aspek evaluasi kinerja. Rincian nilai untuk masing-masing metrik pada setiap kategori penyakit dapat dilihat secara detail dalam Tabel 3.

**Tabel 3.** Laporan Klasifikasi

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Tomato_Bacterial_spot	0.94	0.80	0.87	150
Tomato_Early_blight	0.79	0.93	0.85	150
Tomato_Late_blight	0.94	0.83	0.88	150
Tomato_Leaf_Mold	0.95	0.93	0.94	150
Tomato_Septoria_leaf_spot	0.91	0.90	0.90	150
Tomato_Spider_mites	0.88	0.93	0.90	150
Tomato_Target_Spot	0.85	0.87	0.86	150
Tomato_Tomato_Yellow_Leaf_Curl_Virus	1.00	0.89	0.94	150
Tomato_Tomato_mosaic_virus	0.98	1.00	0.99	150
Tomato_healthy	0.88	0.99	0.93	150
<b>Accuracy</b>			0.91	1500
<b>Macro avg</b>	0.91	0.91	0.91	1500
<b>Weighted avg</b>	0.91	0.91	0.91	1500

## 4 Kesimpulan

Penelitian ini berhasil mengembangkan model *Convolutional Neural Network* (CNN) untuk deteksi penyakit daun tomat dengan akurasi validation set 95,84% dan test set 91%. Hasil akurasi training yang lebih rendah dari akurasi validasi pada model ini kemungkinan disebabkan oleh penggunaan augmentasi data yang signifikan pada dataset training. Augmentasi data membuat tugas pembelajaran pada data training menjadi lebih sulit dengan menyajikan berbagai transformasi gambar, sedangkan data validasi tidak mengalami augmentasi yang sama. Akibatnya, model mungkin berkinerja lebih baik pada data validasi yang relatif lebih mudah dibandingkan dengan data training yang sudah diaugmentasi. Meskipun terdapat beberapa kesalahan klasifikasi pada penyakit dengan kemiripan visual, sistem berbasis CNN ini tetap menunjukkan potensi aplikasi dalam pertanian modern untuk deteksi dini penyakit daun tomat secara akurat dan efisien, sehingga dapat membantu petani mengurangi kerugian dan meningkatkan hasil panen. Untuk penelitian selanjutnya, disarankan penambahan data pelatihan pada kategori penyakit dengan akurasi rendah, penerapan teknik regularisasi yang lebih kuat untuk meningkatkan generalisasi model, eksplorasi arsitektur *transfer learning* seperti ResNet atau EfficientNet untuk ekstraksi fitur yang lebih baik, implementasi teknik *attention mechanism* untuk fokus pada area terinfeksi penyakit, serta pengembangan sistem deteksi *real-time* yang dapat diintegrasikan dengan perangkat *mobile* untuk aplikasi praktis di lapangan.

## Referensi

- [1] R. C. Sigitta, R. H. Saputra, and F. Fathulloh, "Deteksi Penyakit Tomat melalui Citra Daun menggunakan Metode Convolutional Neural Network," AVITEC, vol. 5, no. 1, p. 43, Feb. 2023, doi: 10.28989/avitec.v5i1.1404.
- [2] G. Chopra and P. Whig, "Analysis of Tomato Leaf Disease Identification Techniques," Journal of Computer Science and Engineering (JCSE), vol. 2, no. 2, pp. 98–103, Aug. 2021, doi: 10.36596/jcse.v2i2.171.
- [3] R. H. Putra, H. M. Ridwan, I. Abiansyah, and T. Agustin, "SEMINAR NASIONAL AMIKOM SURAKARTA (SEMNASA) 2024 KLASIFIKASI DAUN TOMAT SEHAT DAN TERSERANG PENYAKIT MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)", [Online]. Available: <https://www.kaggle.com/datasets/kaustubhb999/tomatoleaf>.
- [4] R. Soekarta, N. Nurdjan, and A. Syah, "Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN)," vol. 8, no. 2, 2023.
- [5] A. Nurdin, D. Satria, Y. Kartika, A. Rezha, and E. Najaf, "Klasifikasi Penyakit Daun Tomat Dengan Metode Convolutional Neural Network Menggunakan Arsitektur Inception-V3 KATA KUNCI Daun Tomat Convolutional Neural Network Klasifikasi Inception V3 KORESPONDENSI."
- [6] D. Hemalatha and A. Begum, "Image Identification and Classification Using CNN," 2021.
- [7] S. Auliaddina and T. Arifin, "SISTEMASI: Jurnal Sistem Informasi Penggunaan Data Augmentasi dan Hyperparameter Tuning dalam Klasifikasi Jenis Batik menggunakan Model CNN Use of Augmentation Data and Hyperparameter Tuning in Batik Type Classification Using the CNN Model." [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [8] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," J Big Data, vol. 6, no. 1, Dec. 2019, doi: 10.1186/s40537-019-0197-0.
- [9] Q. Wang, F. Qi, M. Sun, J. Qu, and J. Xue, "Identification of Tomato Disease Types and Detection of Infected Areas Based on Deep Convolutional Neural Networks and Object Detection Techniques," Comput Intell Neurosci, vol. 2019, 2019, doi: 10.1155/2019/9142753.
- [10] D. L. Shanthi, K. Vinutha, N. Ashwini, and S. Vashistha, "Tomato Leaf Disease Detection Using CNN," in Procedia Computer Science, Elsevier B.V., 2024, pp. 2975–2984. doi: 10.1016/j.procs.2024.04.281.
- [11] M. V. Sanida, T. Sanida, A. Sideris, and M. Dasycen, "An Efficient Hybrid CNN Classification Model for Tomato Crop Disease," Technologies (Basel), vol. 11, no. 1, Feb. 2023, doi: 10.3390/technologies11010010.
- [12] N. Awalia and A. Primajaya, "IDENTIFIKASI PENYAKIT LEAF MOLD DAUN TOMAT MENGGUNAKAN MODEL DENSENET121 BERBASIS TRANSFER LEARNING," vol. 8, no. 1, 2022, [Online]. Available: <http://ejournal.fikom-unasman.ac.id>
- [13] M. Astiningrum, P. Prima Arhandi, N. Aqmarina Ariditya, J. Teknologi Informasi, and P. Negeri Malang, "JIP (Jurnal Informatika Polinema) IDENTIFIKASI PENYAKIT PADA DAUN TOMAT BERDASARKAN FITUR WARNA DAN TEKSTUR".
- [14] M. G. Pradana, H. Khoirunnisa, and I. W. R. Pinastawa, "Evaluation of Convolutional Neural Network Model Architecture Performance," pp. 628–632, 2023, doi: 10.1109/icimcis60089.2023.10349075.
- [15] P. Baser, J. R. Saini, and K. Kotcha, "TomConv: An Improved CNN Model for Diagnosis of Diseases in Tomato Plant Leaves," in Procedia Computer Science, Elsevier B.V., 2023, pp. 1825–1833. doi: 10.1016/j.procs.2023.01.160.
- [16] A. Yogyanto, A. Maulana, and D. A. Tri Cahyo, "Penerapan Metode Convolutional Neural Network (CNN) Dalam Klasifikasi Penyakit Tanaman Jagung."
- [17] C. R. Kotta, D. Paseru, M. Sumampouw, T. Informatika, U. Katolik De La Salle Manado, and K. I. Kombos Manado -, "Implementasi Metode Convolutional Neural Network untuk Mendeteksi Penyakit pada Citra Daun Tomat Implementation of Convolutional Neural Network Method to Detect Diseases in Tomato Leaf Image."
- [18] I. W. R. Pinastawa, M. G. Pradana, and K. Khoironi, "Edge Detection Model Performance Using Canny, Prewitt and Sobel in Face Detection," Sinkron, vol. 8, no. 2, pp. 623–631, Mar. 2024, doi: 10.33395/sinkron.v8i2.13497.

- [19] A. Maysela, N. Rohma, and N. Penulis:, “Diagnosa Penyakit Tanaman Tomat pada Citra Daun Menggunakan Metode Convolutional Neural Network (CNN),” JIMU, 2024.
- [20] P. Mishra, A. Biancolillo, J. M. Roger, F. Marini, and D. N. Rutledge, “New data preprocessing trends based on ensemble of multiple preprocessing techniques,” Nov. 01, 2020, Elsevier B.V. doi: 10.1016/j.trac.2020.116045.
- [21] K. Dillliwar, S. Mandal, N. Sahu, M. K. Shriwas, and R. Lanjewar, “Plant Disease Detection Using Convolutional Neural Networks (CNNs).”