

Klasifikasi Jenis Penyakit Tanaman Cabai Menggunakan Arsitektur *DenseNet201*

Naninda Uswatun Khasanah¹, Muhammad Fachrie²

^{1,2}Informatika, Sains & Teknologi, Universitas Teknologi Yogyakarta
Jl. Ring Road Utara Jombor Lor, Yogyakarta, Indonesia

e-mail: naninda.5210411276@student.uty.ac.id¹, muhammad.fachrie@staff.uty.ac.id²

Received : October, 2024

Accepted : November, 2024

Published : December, 2024

Abstract

Chili plants are an important commodity in Indonesia with significant economic value. However, chili production is often disrupted by various diseases that can reduce yields and cause economic losses for farmers. This research offers an innovation in the form of an automatic chili disease classification system based on Convolutional Neural Network (CNN) using the DenseNet201 architecture, which has not been widely applied in the agricultural sector in Indonesia. The dataset used was obtained from the Kaggle platform under the name "Chili Plant Disease", convolutional neural network (CNN), Densenet201, disease classification, chili plant. The model was trained using the Adam optimizer and the sparse categorical crossentropy loss function. The training results indicate that the model achieved a maximum accuracy of 90% at epoch 150 with a minimum loss value of 0.0426. In testing with the test data, the model achieved an accuracy of 84%. This classification system is expected to assist farmers in quickly and accurately detecting diseases, enabling more effective preventive measures and enhancing the productivity and quality of chili crop yields in Indonesia.

Keywords: convolutional neural network (CNN), Densenet201, disease classification, chili plant

Abstrak

Tanaman cabai merupakan komoditas penting di Indonesia dengan nilai ekonomi yang signifikan. Namun, produksi cabai sering kali terganggu oleh berbagai penyakit yang dapat menurunkan hasil panen dan menyebabkan kerugian ekonomi bagi petani. Penelitian ini mengusulkan pendekatan baru dalam bentuk sistem klasifikasi otomatis penyakit cabai menggunakan arsitektur DenseNet201 yang pertama kali diterapkan pada sektor agrikultur di Indonesia, menawarkan peningkatan akurasi deteksi dibanding metode klasifikasi tradisional. Dataset yang digunakan diperoleh dari platform Kaggle dengan nama "Chili Plant Disease", terdiri dari 500 citra yang dikelompokkan ke dalam lima kelas: healthy, leaf curl, leaf spot, whitefly, dan yellowish. Model dilatih menggunakan optimizer Adam dan fungsi loss sparse_categorical_crossentropy. Hasil pelatihan menunjukkan bahwa model mencapai akurasi tertinggi sebesar 90% pada epoch ke-150 dengan nilai loss terendah 0.0426. Pada pengujian dengan data uji, model mencapai akurasi sebesar 84%. Sistem klasifikasi ini diharapkan dapat membantu petani mendeteksi penyakit secara cepat dan akurat, memungkinkan tindakan pencegahan yang lebih efektif serta meningkatkan produktivitas dan kualitas hasil panen cabai di Indonesia.

Kata Kunci: convolutional neural network (CNN), Densenet201, klasifikasi penyakit, tanaman cabai

1. PENDAHULUAN

Tanaman cabai atau *Chili plants* merupakan jenis sayuran yang semakin diminati karena memiliki nilai ekonomi yang tinggi. Dengan berkembangnya industri yang membutuhkan cabai sebagai bahan baku, permintaan terhadap cabai terus meningkat [1]. Di Indonesia,

tanaman ini memiliki peran penting karena sebagian besar masyarakat menyukai makanan pedas. Dalam beberapa tahun terakhir, banyak petani mulai membudidayakan cabai sebagai alternatif yang menjanjikan [2].

Namun, budidaya tanaman cabai tidak lepas dari tantangan, salah satunya adalah serangan berbagai jenis penyakit yang dapat menyebabkan penurunan produktivitas[3]. Beberapa jenis penyakit tanaman cabai yaitu penyakit *leaf curl* (daun keriting) yang disebabkan oleh infeksi virus, seperti *Tomato Yellow Leaf Curl Virus* (TYLCV). Infeksi ini menyebabkan daun melengkung dan mengerut, sehingga mengganggu pertumbuhan tanaman. Penyakit *leaf spot* yang ditandai dengan bercak coklat pada daun akibat infeksi jamur atau bakteri, dapat mengganggu proses fotosintesis dan mengurangi hasil panen. Hama seperti *whitefly* juga merupakan ancaman serius bagi tanaman cabai, karena mereka menghisap cairan tanaman, yang dapat mengakibatkan daun menguning dan layu. Penyakit *yellowish* yang disebabkan oleh virus yang ditularkan oleh kutu kebul, juga menyebabkan perubahan warna daun menjadi kuning, sehingga mempengaruhi pertumbuhan tanaman. Dengan demikian, penanganan yang tepat dan pengendalian penyakit sangat penting untuk menjaga kesehatan dan produktivitas tanaman cabai.

Bagi para petani, penyakit tanaman cabai seringkali sulit untuk diidentifikasi secara cepat dan akurat. Kurangnya pengetahuan mengenai jenis-jenis penyakit yang menyerang cabai sering menyebabkan keterlambatan dalam pengambilan tindakan pencegahan dan penanganan, yang pada akhirnya dapat menyebabkan kerugian ekonomi yang signifikan [4]. Penurunan hasil panen dan meluasnya penyebaran penyakit adalah risiko utama yang dihadapi jika penyakit tidak terdeteksi sejak dini [5].

Penelitian pernah dilakukan oleh Avianto & Handayani (2023) mengembangkan "sistem klasifikasi penyakit antraknosa pada cabai merah teropong "Inko Hot" menggunakan metode *Convolutional Neural Network*". Penelitian ini bertujuan membedakan buah cabai merah besar yang normal dan terinfeksi antraknosa dari citra inputan. Data terdiri dari 1000 citra cabai (500 normal, 500 terinfeksi) yang diperoleh melalui survei dan wawancara di Desa Widoro, Sleman, Yogyakarta, serta 500 citra sayuran lain sebagai pembanding. Pengujian dengan 6 citra baru menunjukkan akurasi prediksi 83,33%, dengan 5 dari 6 citra diklasifikasikan dengan benar [6]. Akan tetapi, penelitian ini hanya terbatas pada satu jenis penyakit yaitu 'antraknosa' dan tidak mempertimbangkan faktor-faktor lingkungan yang dapat mempengaruhi gejala penyakit.

Penelitian pernah dilakukan oleh Ningrum et al. (2024) yang berjudul "Klasifikasi dan Pengenalan Pola Penyakit Cabai dengan Metode CNN (*Convolutional Neural Network*).". Penelitian ini bertujuan untuk mengembangkan sistem pendeteksi penyakit pada cabai menggunakan metode CNN. Data gambar digital cabai Asmoro diambil menggunakan kamera ponsel beresolusi 104 Megapiksel, yang terdiri dari 162 gambar (105 cabai kering dan 57 cabai mentah), kemudian dibagi menjadi 80% data training dan 20% data testing. Hasilnya, sistem klasifikasi penyakit cabai dengan CNN mencapai akurasi sempurna sebesar 100% dengan 162 gambar cabai yang telah dikenali. Namun, saat ditambahkan 74 gambar baru sehingga total datanya menjadi 236, akurasi algoritma tersebut turun menjadi 45%[7]. Penurunan akurasi ini mengindikasikan tantangan yang dihadapi dalam pengembangan model yang mampu beradaptasi dengan data baru dan variasi gejala penyakit di lapangan.

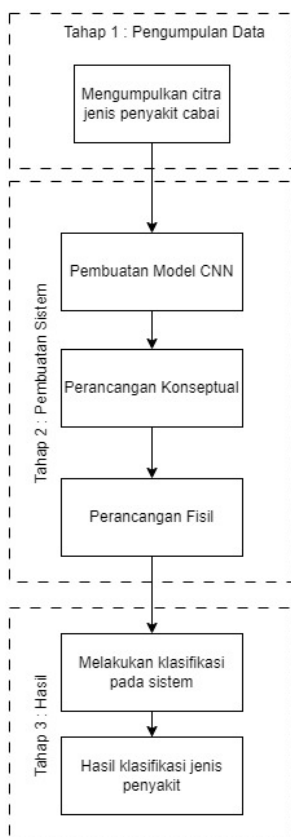
Penelitian pernah dilakukan oleh Putra et al. (2023) yang berjudul "Implementasi Pendeteksi Penyakit pada Daun Alpukat Menggunakan Metode CNN.". Penelitian ini bertujuan untuk mendeteksi dan mengklasifikasikan jenis penyakit pada daun alpukat. Dataset yang digunakan terdiri dari 265 gambar daun alpukat, terbagi menjadi 3 kategori: 105 gambar daun dengan embun jelaga, 51 gambar penyakit kuning, dan 109 gambar penyakit *cercospora*. Data tersebut dibagi menjadi 212 gambar untuk training, 52 gambar untuk testing, dan 30

gambar sebagai data kasus lapangan. Pada proses *training*, akurasi tertinggi yang dicapai adalah 97,4% pada *epoch* ke-8 dengan nilai *loss* sebesar 0,1962. Sementara itu, pada proses testing dengan 30 data kasus lapangan, metode CNN mampu mengklasifikasikan jenis penyakit daun alpukat dengan akurasi 80%[8].

Dari penelitian yang telah dilakukan sebelumnya, para peneliti telah mencoba mengembangkan sistem klasifikasi tetapi masih terdapat beberapa kesenjangan. Antara lain seperti keterbatasan jenis penyakit yang dapat diklasifikasi, penurunan akurasi yang signifikan saat menghadapi data baru, dan kurangnya pertimbangan variasi gejala berdasarkan kondisi lingkungan.

2. METODE PENELITIAN

Adapun alur penelitian untuk sistem klasifikasi yang ditunjukkan pada gambar 1.



Gambar 1. Alur penelitian

Gambar 1 merupakan alur metode penelitian dalam pembuatan sebuah sistem klasifikasi. Pada tahapan pertama yaitu melakukan pengumpulan data citra penyakit tanaman cabai. Setelah itu, melakukan tahapan

Berdasarkan permasalahan tersebut, rumusan masalah dalam penelitian ini adalah bagaimana mengembangkan sistem klasifikasi penyakit cabai yang akurat dan adaptif menggunakan arsitektur DenseNet201. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi jenis penyakit cabai yang dapat mendeteksi berbagai jenis penyakit dengan menggunakan arsitektur DenseNet201. Tujuan adanya sistem klasifikasi menggunakan arsitektur DenseNet201, diharapkan petani dapat lebih mudah mendeteksi jenis penyakit yang menyerang tanaman cabai mereka, memungkinkan tindakan pencegahan dan penanganan yang lebih cepat dan tepat. Hal ini pada akhirnya dapat meningkatkan kualitas dan kuantitas produksi cabai di Indonesia.

yang kedua yaitu melakukan pembuatan model CNN dengan menggunakan arsitektur *DenseNet201*, dengan menggunakan arsitektur tersebut diharapkan dapat menciptakan sistem klasifikasi jenis penyakit tanaman dengan akurat. Dalam tahapan kedua juga memerlukan alur konseptual sistem untuk menciptakan sistem klasifikasi yang mudah digunakan dan interatif. Selanjutnya tahapan terakhir yaitu melakukan proses klasifikasi, dalam tahapan ini sistem harus dapat mengklasifikasi jenis penyakit secara akurat.

2.1 Pengumpulan Data





Sumber data yang digunakan untuk mengklasifikasikan jenis penyakit pada tanaman cabai menggunakan CNN adalah data sekunder. Data ini diambil dari Kaggle dengan nama dataset "*Chili Plant Disease*". Dataset tersebut berupa gambar dengan total 500 citra yang dikelompokkan ke dalam 5 kategori berdasarkan jenis penyakit cabai, yaitu *healthy*, *leaf curl*, *leaf spot*, *whitefly*, dan *yellowish*. Untuk detail dari dataset yang digunakan dalam penelitian dapat dilihat pada Tabel 1.


Tabel 1. Jumlah Data

Kelas	Data Latih	Data Uji	Data Validasi
<i>healthy</i>	80	50	50
<i>leaf curl</i>	80	50	50
<i>leaf spot</i>	80	50	50
<i>whitefly</i>	80	50	50
<i>yellowish</i>	80	50	50
Total			500

Tabel 1 memperlihatkan jumlah dari citra penyakit tanaman cabai yang digunakan sebagai data latih, data uji, dan juga data validasi. Dataset penelitian ini dibagi menjadi data latih, uji, dan validasi untuk memastikan model mampu mengenali pola dan menggeneralisasi data baru dengan baik. Data latih (60-80%) digunakan untuk melatih model, data validasi (10-20%) untuk memantau performa selama pelatihan dan mencegah overfitting, sementara data uji (10-20%) digunakan untuk mengukur kemampuan model pada data yang belum pernah dilihat. Pembagian dataset dilakukan secara acak atau dengan stratifikasi agar distribusi setiap kategori penyakit seimbang, sehingga model dapat bekerja secara optimal dan akurat dalam mendeteksi berbagai jenis penyakit cabai[9].

Tabel 2. Sampel Penyakit Tanaman Cabai

Kelas	Gambar
<i>healthy</i>	
<i>leaf curl</i>	
<i>leaf spot</i>	
<i>whitefly</i>	

<i>yellowish</i>	
------------------	---

Pada Tabel 2 ditampilkan beberapa sampel dataset gambar dari masing-masing jenis penyakit tanaman cabai. Gambar tersebut menunjukkan lima jenis penyakit tanaman cabai yaitu *healthy*, *leaf curl*, *leaf spot*, *whitefly*, dan *yellowish*.

2.2 Pembuatan Sistem

2.2.1 Pembuatan Model CNN


Pada pembuatan sistem ini menggunakan model CNN yaitu *Densenet201* serta menambahkan beberapa layer yaitu Layer *Dropout* dengan rasio 0.2 diterapkan untuk mencegah *overfitting* dengan membuang 20% *neuron* secara acak. *Output* dari model DenseNet pra-latih diratakan menjadi vektor 1D menggunakan layer *Flatten*. Selanjutnya, tiga layer *Dense (Fully Connected)* ditambahkan dengan jumlah neuron masing-masing 64, dan 5. Layer *Dense* pertama dan kedua menggunakan fungsi aktivasi *ReLU (Rectified Linear Unit)*, sedangkan layer terakhir menggunakan fungsi aktivasi *Softmax* untuk klasifikasi multi-kelas. Tabel 3 merupakan arsitektur CNN model DenseNet201 yang digunakan untuk membuat sistem klasifikasi.

Tabel 3. Model DenseNet201

Layer (type)	Output shape	Param #
sequential (Sequential)	(None, 224, 224, 3)	0
densenet201 (Functional)	(None, 1920)	18321984
dropout_2 (Dropout)	(None, 1920)	0
flatten_3 (Flatten)	(None, 1920)	0
dense_9 (Dense)	(None, 64)	122944
dense_10 (Dense)	(None, 64)	4160
dense_11 (Dense)	(None, 5)	325
Total params: 18449413 (70.38 MB)		
Trainable params: 127429 (497.77 KB)		
Non-trainable params: 18321984 (69.89 MB)		

2.2.1 Perancangan Konseptual

Perancangan konseptual dilakukan agar dapat mengetahui tahapan-tahapan dibentuknya sistem klasifikasi jenis penyakit pada tanaman cabai. Pada awalnya melakukan *import* dataset untuk dilakukan proses *preprocessing* yang meliputi *Data Preparation* dan *Augmentasi Data*, selanjutnya akan dilakukan proses *training* dan *testing*. Pada Gambar 2 merupakan *flowchart* sistem.



Gambar 2. Flowchart Sistem

Pada gambar 2 terdapat bagian tahap *preprocessing*, tahap yang pertama adalah melakukan data *preparation*. Data *preparation* merupakan tahapan untuk mempersiapkan data mentah yang sesuai kebutuhan yang digunakan dalam pembuatan model[10], dalam pembuatan tidak dilakukan pembagian data dikarenakan data sudah dibagi sebelumnya. Selanjutnya dalam tahap augmentasi data, peneliti menerapkan empat jenis pemrosesan, yaitu *RandomFlip*, *RandomRotation*, *RandomZoom*, dan *Rescaling*. Augmentasi data ini bertujuan untuk mengurangi *overfitting* dengan upaya yang seminimal mungkin[11][12].

Pada *training* atau pelatihan model *DenseNet201*, pelatihan model yang disusun menggunakan *loss function* berupa *Sparse Categorical Crossentropy*. Pada pelatihan ini juga diberikan *Optimizer* yaitu berupa *Adam Optimizer* yang menggunakan *Accuracy* untuk melakukan *metrics* pengukuran performanya[13].

Proses *testing* atau proses klasifikasi jenis penyakit tanaman cabai dilakukan dengan menggunakan data uji yang telah disiapkan [14]. Proses ini mampu mengklasifikasikan jenis-jenis penyakit pada tanaman cabai dari citra gambar yang di *input*. Algoritma *Densenet201* telah di *training* untuk dapat mengklasifikasi citra yang berupa jenis penyakit tanaman cabai dengan beberapa kelas yaitu *healthy*, *leaf curl*, *leaf spot*, *whitefly*, *yellowish*. Hasil *testing* akan menampilkan citra yang di *input* dengan hasil klasifikasi yang benar dan akurat.

2.2.3 Perancangan Fisik

Untuk menciptakan tampilan sistem yang interaktif, penulis melakukan rancangan fisik untuk tampilan sistem klasifikasi jenis penyakit pada tanaman cabai. Pada tampilan sistem terdapat 3 menu utama, yaitu tampilan menu utama, tampilan menu *about*, dan tampilan menu *testing*. Pada Gambar 3 yaitu tampilan menu utama yang terdapat nama sistem klasifikasi. Di bagian kiri terdapat judul dan deskripsi singkat sistem, serta tombol "**Start Testing**" untuk memulai pengujian. Ilustrasi cabai di sebelah kanan menambah daya tarik visual, sedangkan navigasi di bagian atas memudahkan pengguna berpindah antar halaman.



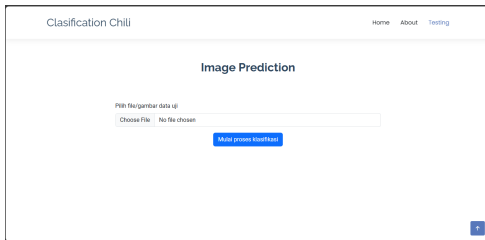
Gambar 3. Halaman Utama

Pada Gambar 4 merupakan halaman *about*. Tampilan halaman *about* menjelaskan tujuan dari sistem, yaitu membantu petani mengidentifikasi penyakit pada tanaman cabai menggunakan algoritma *Convolutional Neural Network (CNN)*. Sistem ini dapat mengklasifikasi penyakit secara otomatis melalui gambar cabai yang diunggah oleh user.



Gambar 4. Halaman About


Gambar 5 menunjukkan tampilan menu *testing*, yang dilengkapi dengan *form* untuk menginput citra penyakit tanaman cabai agar bisa diklasifikasikan. Cara kerjanya adalah ketika pengguna mengunggah gambar penyakit tanaman cabai melalui form yang disediakan, sistem akan memprosesnya dan menampilkan hasil klasifikasi, yaitu berupa data input serta jenis penyakit yang terdeteksi.



Gambar 5. Halaman Pengujian

2.3 Convolutional Neural Network

CNN (*Convolutional Neural Networks*) adalah sebuah metode dalam pembelajaran mesin yang menggunakan jaringan saraf tiruan, khususnya dirancang untuk mengolah data gambar. Data gambar yang diberikan biasanya memiliki dimensi berupa Panjang \times Lebar \times channel warna, di mana Panjang dan Lebar merepresentasikan ukuran gambar dalam satuan pixel. Channel warna menggambarkan jenis warna dalam gambar, misalnya gambar grayscale hanya memiliki 1 channel, sementara gambar berwarna biasa memiliki 3 channel yang mewakili warna dasar RGB (Merah, Hijau, Biru). Seperti jaringan saraf tiruan lainnya, CNN dilengkapi dengan bobot, bias, dan fungsi aktivasi yang memungkinkan jaringan menghasilkan keluaran yang sesuai berdasarkan data pelatihan yang digunakan [15]. Tahapan-tahapan CNN dapat dilihat pada Gambar 6.




Gambar 6. Tahapan Arsitektur CNN
[Sumber:[16]]

Gambar 6 menunjukkan tahapan-tahapan dalam *Convolutional Neural Network* (CNN). CNN memiliki dua tahapan utama, yaitu feature learning dan classification. Feature learning merupakan teknik di mana model secara otomatis dan adaptif melakukan proses

ekstraksi fitur dari data input, seperti gambar atau sinyal, untuk menangkap pola penting yang dapat membantu dalam proses klasifikasi. Tahapan ini biasanya melibatkan beberapa lapisan konvolusi dan pooling yang berfungsi untuk menyaring fitur-fitur dari data input secara bertahap. Setelah fitur-fitur penting diekstraksi, tahap classification bertujuan untuk mengklasifikasikan setiap fitur yang telah diperoleh selama proses feature learning ke dalam kategori yang sesuai. Proses klasifikasi ini biasanya dilakukan menggunakan lapisan fully connected di akhir jaringan, yang menghasilkan keputusan akhir berupa prediksi kelas[17].

2.3 DenseNet201

DenseNet201 merupakan sebuah arsitektur *Convolutional Neural Network* (CNN) yang diciptakan oleh Gao Huang sebagai penemu utamanya. Arsitektur ini dirancang untuk mengatasi masalah vanishing gradient yang sering terjadi pada neural network yang memiliki lapisan (*layer*) yang sangat banyak atau dalam. Ketika sebuah *neural network* semakin dalam dengan lapisan yang terus bertambah, gradien yang dipelajari akan semakin berkurang atau hilang. Kondisi ini menyebabkan lapisan-lapisan awal kehilangan kemampuan untuk mempelajari fitur-fitur rendah (*low-level features*) yang penting. Dengan konsep *densely connected* atau koneksi yang padat antar lapisan, *DenseNet201* memungkinkan aliran gradien dapat diteruskan dengan lebih baik ke lapisan-lapisan sebelumnya. Hal ini membuat proses pembelajaran pada lapisan awal tetap dapat berjalan dengan efektif, meskipun jumlah lapisan dalam arsitektur ini sangat banyak [18][NO_PRINTED_FORM].



Gambar 7. Tahapan DenseNet201
[Sumber: [18]]

3. HASIL DAN PEMBAHASAN

3.1 Training Dataset

Model arsitektur *DenseNet201* dilatih menggunakan berbagai kombinasi *hyperparameter* untuk mengoptimalkan kinerja. Beberapa parameter penting yang diatur

meliputi fungsi *loss*, *optimizer*, *learning rate*, *batch size*, dan jumlah *epoch*. Fungsi *loss* yang digunakan adalah *sparse categorical_crossentropy*, yang cocok untuk klasifikasi dengan beberapa kategori. Sementara itu, *optimizer* yang dipilih adalah Adam. *Optimizer Adam* tersebut digunakan karena kemampuannya untuk mempercepat proses konvergensi dan kestabilan dalam optimasi model [19]. Model *DenseNet201* dilatih dengan menggunakan beberapa konfigurasi parameter untuk mengevaluasi pengaruhnya terhadap performa. Tabel 4 merupakan beberapa percobaan dengan menggunakan parameter yang berdeda-beda.

Percobaan kedua dilakukan dengan mengubah *learning rate* menjadi 0,0001, meningkatkan *batch size* menjadi 64, dan menggunakan 40 *epoch*. Pada konfigurasi ini, performa model justru menurun, dengan *loss* meningkat menjadi 0,8221 dan *accuracy* menurun menjadi 0,6850. Hasil ini menunjukkan bahwa *learning rate* yang terlalu kecil memperlambat proses pembelajaran model, yang berdampak pada peningkatan *loss* dan penurunan *accuracy*.

Percobaan berikutnya menunjukkan peningkatan performa model. Pada konfigurasi dengan *learning rate* 0,001, *batch size* 32, dan

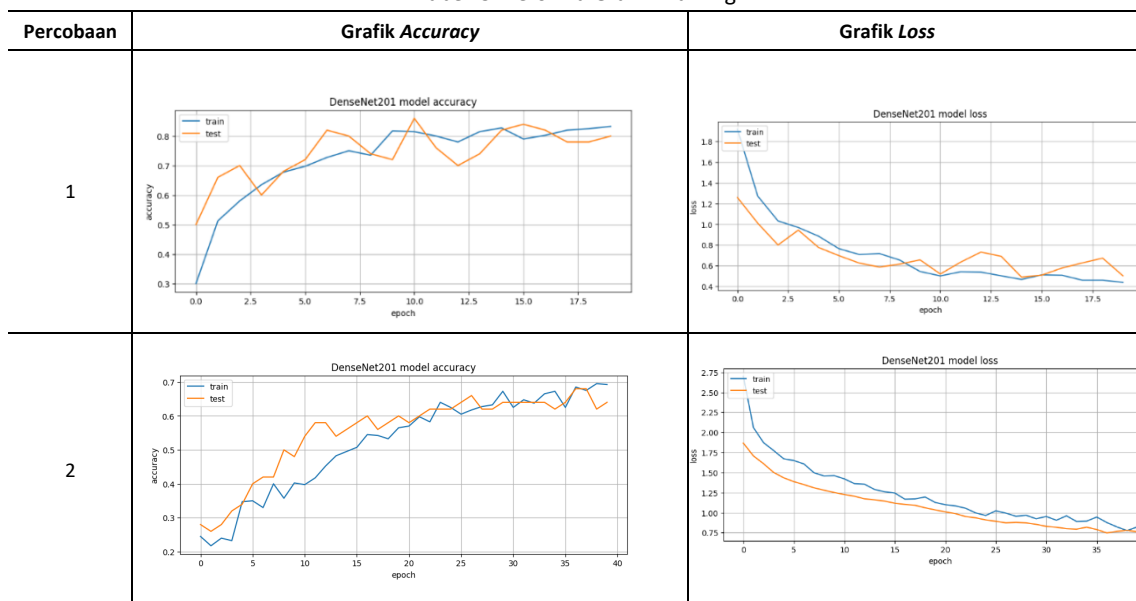
Tabel 4. Hasil Percobaan Training DenseNet201

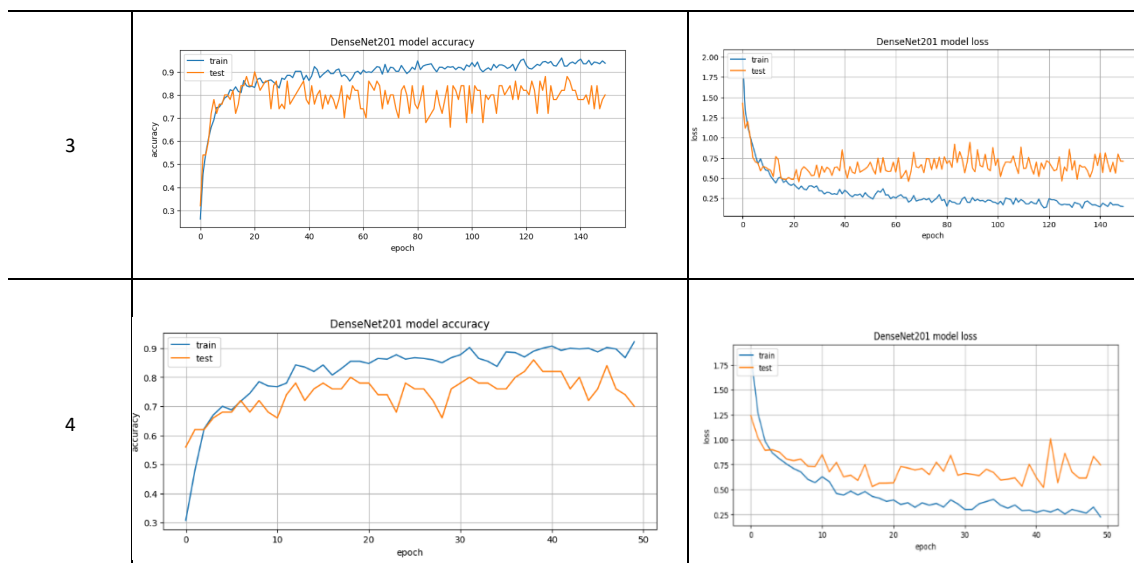
Perco baan	Parameter					Hasil	
	Loss	Optimizer	Learning rate	Batch size	epoch	loss	Accuracy
1	<i>sparse_categorical_crossentropy</i>	Adam	0,001	32	20	0.4999	0.8600
2	<i>sparse_categorical_crossentropy</i>	Adam	0.0001	64	40	0.8221	0.6850
3	<i>sparse_categorical_crossentropy</i>	Adam	0.001	32	150	0.0426	0,9000
4	<i>sparse_categorical_crossentropy</i>	Adam	0.001	32	50	0.2886	0.8900

Pada percobaan pertama, model menggunakan *learning rate* sebesar 0,001, *batch size* 32, dan jumlah *epoch* sebanyak 20. Hasil pelatihan menunjukkan bahwa model memiliki *loss* sebesar 0,4999 dan *accuracy* sebesar 0,8600. Meskipun hasilnya cukup baik, nilai *loss* yang masih relatif tinggi mengindikasikan ruang untuk perbaikan lebih lanjut.

40 *epoch*, model arsitektur *DenseNet201* mampu menurunkan *loss* menjadi 0,1520 dengan *accuracy* sebesar 0,9000. Pada percobaan terbaik, dengan jumlah *epoch* yang lebih besar, yaitu 150, nilai *loss* dapat ditekan hingga 0,0426 dan *accuracy* mencapai 0,9000. Hal ini mengindikasikan bahwa peningkatan jumlah *epoch* memungkinkan model untuk

Tabel 5. Peforma Grafik Training





mempelajari pola lebih baik dari dataset yang digunakan [20].

Beberapa percobaan yang telah dilakukan menghasilkan data seperti yang ditampilkan pada Tabel 4. Berdasarkan hasil pengujian dengan menggunakan parameter *optimizer Adam*, terlihat bahwa *loss* terendah dicapai pada percobaan ke-3 dengan nilai 0.0426, sementara akurasi tertinggi diperoleh pada percobaan ke-3 juga, dengan nilai 0.9000. Hal ini mengindikasikan bahwa peningkatan jumlah epoch memungkinkan model untuk mempelajari pola lebih baik dari dataset yang digunakan. Pada pengujian ini, digunakan *sparse categorical crossentropy* sebagai fungsi *loss*, karena data yang digunakan terdiri dari beberapa kelas.

Hasil ini menunjukkan peningkatan performa yang signifikan dibandingkan dengan penelitian sebelumnya yang menggunakan arsitektur DenseNet201 untuk klasifikasi penyakit tanaman cabai. Misalnya, penelitian Avianto & Handayani (2023) hanya mencapai akurasi 0,8500, sementara Ningrum et al. (2024) melaporkan akurasi 0,8700. Keunggulan model DenseNet201 yang dikembangkan dalam penelitian ini dapat dilihat dari kemampuannya mencapai akurasi 0,9000, serta stabilitas performa yang lebih baik selama proses pelatihan, seperti ditunjukkan pada Tabel 5.

Berdasarkan Tabel 5 yang membandingkan grafik performa dari beberapa percobaan. Percobaan ketiga menampilkan stabilitas yang


lebih unggul dibandingkan percobaan lainnya, baik dalam hal *accuracy* maupun *loss*. Grafik menunjukkan tren yang konsisten, dengan sedikit *fluktuasi* selama proses pelatihan, yang menandakan bahwa model mampu mencapai *konvergensi* dengan lebih efisien. *Stabilitas* ini penting karena mengindikasikan bahwa model tidak hanya memiliki kemampuan untuk belajar dari data percobaan keempat, dengan nilai *loss* yang rendah dan *accuracy* yang lebih tinggi, mampu menjaga kinerja yang konsisten dan akurat dalam melakukan klasifikasi, menjadikannya secara optimal, tetapi juga menunjukkan daya generalisasi yang lebih baik, mengurangi risiko *overfitting* yang umumnya terlihat pada percobaan dengan variabilitas tinggi. Hasil ini menunjukkan bahwa sebagai konfigurasi yang paling andal di antara seluruh percobaan yang dilakukan.

Hasil ini menunjukkan peningkatan performa yang signifikan dibandingkan dengan penelitian sebelumnya yang menggunakan arsitektur DenseNet201 untuk klasifikasi penyakit tanaman cabai. Misalnya, penelitian Avianto & Handayani (2023) hanya mencapai akurasi 0,8500, sementara Ningrum et al. (2024) melaporkan akurasi 0,8700. Keunggulan model DenseNet201 yang dikembangkan dalam penelitian ini dapat dilihat dari kemampuannya mencapai akurasi 0,9000, serta stabilitas performa yang lebih baik selama proses pelatihan, seperti ditunjukkan pada Tabel 5.

3.2 Pengujian

Tahap pengujian sistem dilakukan untuk memastikan bahwa sistem yang telah dibangun berfungsi sesuai dengan spesifikasi dan fungsionalitas yang diharapkan. Pengujian ini berfokus pada klasifikasi jenis penyakit pada tanaman cabai. Model terbaik disimpan dalam format .h5, yang kemudian digunakan dalam pengujian untuk mengevaluasi akurasi dan performa sistem dalam mengklasifikasikan penyakit tanaman cabai berdasarkan data citra yang diberikan.

Pengujian ini dilakukan untuk mengevaluasi performa klasifikasi dengan menggunakan data uji. Berdasarkan hasil pengujian, diperoleh akurasi model sebesar 84%. Akurasi ini menunjukkan bahwa model mampu melakukan klasifikasi dengan cukup baik, dimana dari keseluruhan prediksi yang dilakukan, 84% di antaranya adalah prediksi yang benar.







Gambar 8. Confusion Matrix

Gambar 8 menunjukkan *confusion matrix* yang menggambarkan kinerja model klasifikasi pada lima kelas berbeda. Matriks ini menampilkan nilai prediksi model terhadap nilai sebenarnya untuk setiap kelas. Di diagonal utama, terlihat angka-angka yang menunjukkan jumlah prediksi yang benar untuk masing-masing kelas, misalnya, kelas 0, 1, 2, 3, dan 4 memiliki prediksi benar sebanyak 8, 9, 10, 7, dan 8 berturut-turut. Sedangkan angka di luar diagonal utama menunjukkan kesalahan klasifikasi di mana model salah memprediksi kelas yang sebenarnya. Sebagai contoh, kelas 0 diprediksi sebagai kelas 2 sebanyak 1 kali, kelas 1 diprediksi sebagai kelas 0 sebanyak 1 kali, dan sebagainya. Warna pada peta panas menunjukkan intensitas dari jumlah prediksi, di mana warna yang lebih gelap mengindikasikan jumlah prediksi yang lebih tinggi. Secara keseluruhan, matriks kebingungan ini memberikan gambaran visual yang jelas tentang

distribusi kesalahan dan performa model dalam mengklasifikasikan data ke dalam kelas yang tepat. Pada

Tabel 6 merupakan beberapa pengujian pada sistem klasifikasi. Hasil tahap pengujian menunjukkan bahwa, sistem klasifikasi penyakit tanaman cabai yang dikembangkan menggunakan metode *Convolutional Neural Network (CNN)* dengan arsitektur *DenseNet201* telah diuji pada lima citra tanaman cabai yang mencakup berbagai kondisi, baik tanaman sehat maupun yang terkena penyakit. Dari hasil pengujian pada Tabel 6, sistem berhasil mengklasifikasikan dengan benar empat dari lima citra, memberikan tingkat akurasi yang cukup signifikan. Namun, satu citra gagal diidentifikasi dengan tepat, yang diduga disebabkan oleh faktor-faktor seperti pencahayaan yang kurang optimal, adanya noise pada citra, atau adanya variasi penyakit yang belum terwakili secara adekuat dalam data pelatihan.

Tabel 6 Tabel Pengujian CNN

Perobaan	Citra Penyakit Cabai		Hasil Klasifikasi CNN
Ke-	Citra Input	Class Input	Ketepatan
1		Healthy	Akurat
2		Leaf Spot	Akurat
3		yellowish	Tidak Akurat
4		Whitefly	Akurat
5		yellowish	Akurat

Dalam perbandingan dengan penelitian sebelumnya, sistem klasifikasi dengan menggunakan algoritma Densenet201 menunjukkan performa yang lebih stabil. Pada penelitian Avianto & Handayani (2023) melaporkan akurasi 83,33% dengan dataset yang lebih kecil, sementara Ningrum et al. (2024) mencapai 100% akurasi pada data terbatas tetapi mengalami penurunan yang signifikan saat data diperluas. Model DenseNet201 dalam penelitian ini mencapai akurasi 84% dengan dataset yang lebih beragam, menunjukkan keunggulan dalam menghadapi kompleksitas gejala penyakit.

Sistem klasifikasi penyakit tanaman cabai ini diharapkan memberikan kontribusi signifikan bagi petani dengan mendeteksi penyakit secara dini, memungkinkan langkah penanganan lebih cepat dan efektif sehingga meminimalkan kerugian. Sistem ini juga mempercepat identifikasi penyakit, memungkinkan petani fokus pada pengelolaan keseluruhan tanaman, yang berpotensi meningkatkan hasil panen dan efisiensi produksi. Dalam jangka panjang, sistem ini mendukung pertanian cerdas dan berkelanjutan.

4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan penulis mengenai Klasifikasi Jenis Penyakit Tanaman Cabai Menggunakan Arsitektur DenseNet201 didapatkan kesimpulan sebagai berikut:

1. Sistem klasifikasi penyakit pada tanaman cabai menggunakan CNN dengan arsitektur DenseNet201 menunjukkan kinerja yang sangat baik, dengan akurasi tertinggi 90% pada data pelatihan dan 84% pada data uji.
2. Penurunan akurasi pada data uji mengindikasikan tantangan yang dihadapi dalam menghadapi variasi kondisi dunia nyata seperti pencahayaan dan tekstur daun yang beragam.
3. Model ini cukup andal dalam mendeteksi lima jenis penyakit, tetapi masih memerlukan peningkatan untuk menghadapi noise dan variasi kondisi lingkungan.
4. Penelitian ini membuka peluang pengembangan lebih lanjut, termasuk memperluas cakupan jenis penyakit dan

meningkatkan robustitas model terhadap kondisi eksternal yang kompleks.

DAFTAR PUSTAKA

- [1] Tonius Gulo And Darmawan Harefa, "Identifikasi Serangga (Insekta) Yang Merugikan Pada Tanaman Cabai Rawit Di Desa Sisarahili Ekholo Kecamatan Lolowau Kabupaten Nias Sealatan," *Jurnal Sapta Agrica*, Vol. 2, No. 1, Pp. 50–61, May 2023, Doi: 10.57094/Jsa.V2i1.917.
- [2] R. I. Wati, S. Subejo, And Y. F. Maulida, "Problematika, Pola, Dan Strategi Petani Dalam Mempersiapkan Regenerasi Di Daerah Istimewa Yogyakarta," *Jurnal Ketahanan Nasional*, Vol. 27, No. 2, P. 187, Oct. 2021, Doi: 10.22146/Jkn.65568.
- [3] Gita Srihidayati And R. Randi, "Pengendalian Hama Lalat Buah (Bactrocera Spp.) Menggunakan Pestisida Nabati Limbah Kulit Singkong Dan Biji Mahoni Pada Tanaman Cabai Merah (Capsicum Annuum L.)," *Wanatani*, Vol. 4, No. 1, Pp. 62–73, Jun. 2024, Doi: 10.51574/Jip.V4i1.253.
- [4] T. Hidayat, K. Dinata, A. Ishak, And E. Ramon, "Identifikasi Hama Tanaman Cabai Merah Dan Teknis Pengendaliannya Di Kelompok Tani Sari Mulyo Desa Sukasari Kecamatan Air Periukan Kabupaten Seluma Provinsi Bengkulu," *Agrica Ekstensia*, Vol. 16, No. 1, Jun. 2022, Doi: 10.55127/Ae.V16i1.109.
- [5] A. Qur'ania, L. Karlitasari, S. Maryana, C. Sudrajat, And Z. Zolla, "Identifikasi Defisiensi Unsur Hara Pada Tanaman Cabai Menggunakan Support Vector Machine," *Jurnal Komputer Dan Informatika*, Vol. 11, No. 1, Pp. 62–67, Mar. 2023, Doi: 10.35508/Jicon.V11i1.9803.
- [6] D. Avianto And I. E. Handayani, "Klasifikasi Penyakit Antraknosa Pada Cabai Merah Teropong "Inko Hot" Dengan Metode Convolutional Neural Network," *Sintech (Science And Information Technology) Journal*, Vol. 6, No. 2, Pp. 76–88, Aug. 2023, Doi: 10.31598/Sintechjournal.V6i2.1377.
- [7] B. N. T. C. Ningrum, E. N. Ni'mah, M. P. Arifin, And M. A. D. W. Dara, "Klasifikasi

- Dan Pengenalan Pola Penyakit Cabai Dengan Metode Cnn (Convolution Neural Network)," *Seminar Nasional Teknologi & Sains*, Vol. 3, No. 1, Pp. 125–132, Jan. 2024, Doi: 10.29407/Stains.V3i1.4137.
- [8] J. V. P. P. Putra, F. Ayu, And B. Julianto, "Implementasi Pendeteksi Penyakit Pada Daun Alpukat Menggunakan Metode Cnn," *Stains (Seminar Nasional Teknologi & Sains)*, Vol. 2, No. 1, Pp. 155–162, 2023.
- [9] A. Dwi Putro And H. Tantyoko, "Hybrid Algoritma Vgg16-Net Dengan Support Vector Machine Untuk Klasifikasi Jenis Buah Dan Sayuran," *Jtim : Jurnal Teknologi Informasi Dan Multimedia*, Vol. 5, No. 2, Pp. 56–65, Jul. 2023, Doi: 10.35746/Jtim.V5i2.335.
- [10] F. N. Dhewayani, D. Amelia, D. N. Alifah, B. N. Sari, And M. Jajuli, "Implementasi K-Means Clustering Untuk Pengelompokan Daerah Rawan Bencana Kebakaran Menggunakan Model Crisp-Dm," *Jurnal Teknologi Dan Informasi*, Vol. 12, No. 1, Pp. 64–77, Mar. 2022, Doi: 10.34010/Jati.V12i1.6674.
- [11] D. Putri Ayuni, Jasril, M. Irsyad, F. Yanto, And S. Sanjaya, "Augmentasi Data Pada Implementasi Convolutional Neural Network Arsitektur Efficientnet-B3 Untuk Klasifikasi Penyakit Daun Padi," *Zonasi: Jurnal Sistem Informasi*, Vol. 5, No. 2, Pp. 239–249, May 2023, Doi: 10.31849/Zn.V5i2.13874.
- [12] W.-L. Mao, W.-C. Chen, C.-T. Wang, And Y.-H. Lin, "Recycling Waste Classification Using Optimized Convolutional Neural Network," *Resour Conserv Recycl*, Vol. 164, P. 105132, Jan. 2021, Doi: 10.1016/J.Resconrec.2020.105132.
- [13] K. K. Chandriah And R. V. Naraganahalli, "Rnn / Lstm With Modified Adam Optimizer In Deep Learning Approach For Automobile Spare Parts Demand Forecasting," *Multimed Tools Appl*, Vol. 80, No. 17, Pp. 26145–26159, Jul. 2021, Doi: 10.1007/S11042-021-10913-0.
- [14] D. Hidayat, "Klasifikasi Jenis Mangga Berdasarkan Bentuk Dan Tekstur Daun Menggunakan Metode Convolutional Neural Network (Cnn)," *Intecom: Journal Of Information Technology And Computer Science*, Vol. 5, No. 1, Pp. 98–103, Jun. 2022, Doi: 10.31539/Intecom.V5i1.3401.
- [15] A. T. R. Dzaky, "Deteksi Penyakit Tanaman Cabai Menggunakan Metode Convolutional Neural Network," *E-Proceeding Of Engineering*, Vol. 8, No. 2, Pp. 3039–3055, Apr. 2021.
- [16] P. A. Nugroho, I. Fenriana, And R. Arijanto, "Implementasi Deep Learning Menggunakan Convolutional Neural Network (Cnn) Pada Ekspresi Manusia," *Jurnal Algor*, Vol. 2, No. 1, Pp. 12–21, 2020.
- [17] L. F. S. Scabini And O. M. Bruno, "Structure And Performance Of Fully Connected Neural Networks: Emerging Complex Network Properties," *Physica A: Statistical Mechanics And Its Applications*, Vol. 615, P. 128585, Apr. 2023, Doi: 10.1016/J.Physa.2023.128585.
- [18] A. E. Putra, M. F. Naufal, And V. R. Prasetyo, "Klasifikasi Jenis Rempah Menggunakan Convolutional Neural Network Dan Transfer Learning," *Jurnal Edukasi Dan Penelitian Informatika (Jepin)*, Vol. 9, No. 1, P. 12, Apr. 2023, Doi: 10.26418/Jp.V9i1.58186.
- [19] E. Setia Budi, A. Nofriyaldi Chan, P. Priscillia Alda, And M. Arif Fauzi Idris, "Optimasi Model Machine Learning Untuk Klasifikasi Dan Prediksi Citra Menggunakan Algoritma Convolutional Neural Network," *Resolusi : Rekayasa Teknik Informatika Dan Informasi*, Vol. 4, No. 5, Pp. 502–509, May 2024.
- [20] Weny Indah Kusumawati And Adisaputra Zidha Noorizki, "Perbandingan Performa Algoritma Vgg16 Dan Vgg19 Melalui Metode Cnn Untuk Klasifikasi Varietas Beras," *Journal Of Computer, Electronic, And Telecommunication*, Vol. 4, No. 2, Dec. 2023, Doi: 10.52435/Complete.V4i2.387.