

Klasifikasi Penyakit Antraknosa Pada Cabai Merah Teropong "Inko Hot" Dengan Metode Convolutional Neural Network

Ilmy Eka Handayani¹, Donny Avianto²

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

e-mail: ilmy.5200411217@student.uty.ac.id¹, donny@uty.ac.id²

Received : June, 2023

Accepted : August, 2023

Published : August, 2023

Abstract

The red chili variety "inko hot" is a type of red chili that has a high economic value. Unfortunately, these red chili plants are often infected with anthracnose disease, which results in significant losses for farmers. Anthracnose is one of the major diseases infecting chili plants, potentially resulting in crop failure and losses of up to 80%. The purpose of this study is to develop a classification system to identify anthracnose disease in red chili fruit, using Convolutional Neural Network (CNN) method. In this experiment, 1500 data were used, of which 80% were used as training data and 20% as validation data. The best results of this experiment produced a model with an accuracy of 97% and a loss rate of 6.45%, by applying the Nadam optimization algorithm and going through 50 iterations (epochs). The model showed good performance with a prediction accuracy rate of 83.33%. The development of this classification system has significant potential in providing efficient solutions to recognize diseases in chili plants. Through continuous development, this system can be a valuable tool for farmers to increase crop productivity and reduce the negative impact of disease attacks on red chili peppers and other crops.

Keywords: Anthracnose, Red Chili, Classification System, Convolutional Neural Network.

Abstrak

Cabai merah varietas "inko hot" adalah jenis cabai merah yang memiliki nilai ekonomis yang tinggi. Sayangnya, tanaman cabai merah ini sering terinfeksi penyakit antraknosa, yang berakibat pada kerugian yang signifikan bagi para petani. Antraknosa adalah salah satu penyakit utama yang menginfeksi tanaman cabai, berpotensi mengakibatkan kegagalan panen dan kerugian hingga 80%. Tujuan dari studi ini adalah mengembangkan sistem klasifikasi untuk mengidentifikasi penyakit antraknosa pada buah cabai merah, dengan metode Convolutional Neural Network (CNN). Pada eksperimen ini, terdapat sebanyak 1500 data yang digunakan, di mana 80% diantaranya digunakan sebagai data untuk pelatihan dan 20% sebagai data untuk validasi. Hasil terbaik dari eksperimen ini menghasilkan model dengan akurasi sebesar 97% dan tingkat loss sebesar 6,45%, dengan menerapkan algoritma optimasi Nadam dan melalui 50 iterasi (epochs). Model ini menunjukkan kinerja yang baik dengan tingkat ketepatan prediksi 83,33%. Pengembangan sistem klasifikasi ini memiliki potensi signifikan dalam memberikan solusi yang efisien untuk mengenali penyakit pada tanaman cabai. Melalui pengembangan berkelanjutan, sistem ini dapat menjadi alat berharga bagi para petani untuk meningkatkan produktivitas panen dan mengurangi dampak negatif akibat serangan penyakit pada cabai merah serta tanaman lainnya.

Kata Kunci: Antraknosa, Cabai Merah, Sistem Klasifikasi, Convolutional Neural Network.

1. PENDAHULUAN

Cabai merah besar telah menjadi salah satu komoditas hortikultura yang memiliki nilai

ekonomi yang signifikan di Indonesia. Namun, produksi cabai merah besar kerap dihadapkan pada tantangan akibat faktor-faktor beragam,

dan salah satunya yaitu serangan penyakit antraknosa yang dipicu oleh jamur *Colletotrichum sp*[1]. Penyakit ini memiliki potensi merusak mutu dan kuantitas buah cabai merah besar, yang memberikan dampak negatif terhadap para petani dan juga konsumen[2]. Karena itu, perlu adanya suatu sistem yang memiliki kemampuan untuk mengidentifikasi dan mengklasifikasikan penyakit antraknosa pada buah cabai merah besar dengan tingkat akurasi dan efisiensi yang tinggi.

Klasifikasi penyakit antraknosa pada buah cabai merah besar ialah salah satu hal terpenting sebagai evaluasi untuk hasil buah pada penanaman cabai berikutnya[1]. Petani dapat mengetahui seberapa banyak buah cabai yang terkena penyakit antraknosa dan memberikan pencegahan supaya dapat memastikan mutu cabai merah besar sehingga hasil produksi cabai tetap optimal dan terhindar dari potensi penurunan yang berakibat pada kerugian. Untuk meningkatkan produktivitas hasil panen pertanian, dibutuhkan penanganan dan perawatan yang efektif[1–3]. Cabai merah memiliki banyak jenis, pada penelitian ini menggunakan cabai merah teropong “*inko hot*” sebagai sampel data[4]. Gambar 1 menunjukkan adanya penyakit antraknosa yang diakibatkan oleh jamur *Colletotrichum sp*. Penyakit antraknosa bisa menyerang seluruh tahap pertumbuhan buah cabai merah besar, baik itu yang sudah matang ataupun yang masih muda. Penyakit ini dapat menyebabkan kerusakan hasil buah dan kerugian ekonomi yang signifikan[5]. Berdasarkan latar belakang tersebut, masalah utama yang dihadapi oleh para petani cabai merah besar adalah bagaimana mengenali dan mengklasifikasikan penyakit antraknosa pada buah cabai merah secara tepat dan efisien. Permasalahan ini memiliki urgensi karena dampak dari penyakit antraknosa dapat menimbulkan kerugian ekonomi yang substansial bagi para petani cabai merah besar, dengan potensi kerugian hingga 80% dalam setahun[1]. Maka, diperlukan suatu proses deteksi dan pengklasifikasian guna mengidentifikasi keberadaan penyakit antraknosa pada buah cabai merah besar. Proses klasifikasi ini dilakukan melalui pendekatan *Deep Learning* dengan menerapkan metode *convolutional neural network*[6–8].



Gambar 1. Cabai Antraknosa

Salah satu metode *Deep Learning* yang populer dan efektif untuk klasifikasi citra adalah *Convolutional Neural Network* (CNN). Metode CNN ialah salah satu teknik *Deep Learning* yang populer dan menggunakan algoritma jaringan saraf tiruan untuk memproses data yang masuk melalui beberapa lapisan tersembunyi[6–8]. Dalam menangani masalah klasifikasi citra, CNN menjadi salah satu algoritma *Deep Learning* yang umum digunakan[9]. Metode CNN terbukti mampu memberikan akurasi lebih tinggi ketika melakukan klasifikasi citra dibandingkan menggunakan metode *machine learning* lainnya.

CNN pada umumnya dapat dikembangkan menjadi berbagai arsitektur berbeda, yang secara umum melibatkan 3 lapisan atau *layer* utama yakni *convolutional layer*, *pooling layer*, serta *fully-connected layer*[7,8]. *Convolutional layer* merupakan bagian inti dari CNN sebagai pengganti perkalian matriks umum[6]. Tugas utama dari lapisan konvolusi adalah untuk mendeteksi fitur yang ditemukan di dalam wilayah lokal dari gambar inputan yang umum di seluruh kumpulan data dan memetakan ke *feature map*. Sebuah *feature map* diperoleh untuk setiap filter di lapisan dengan aplikasi berulang dari filter di seluruh subregional dari gambar lengkap, yaitu menggabungkan filter dengan gambar *input*, menambahkan istilah bias, dan kemudian menerapkan fungsi aktivasi[10]. Setelah lapisan konvolusi, selanjutnya menggunakan fungsi aktivasi *non-linier* seperti *ReLU*, *ELU*, atau salah satu varian *Leaky ReLU* lainnya. Lapisan aktivasi yang paling sering digunakan adalah *ReLU*[7]. Lapisan aktivasi pada dasarnya bukan merupakan "lapisan" dalam arti sebenarnya, karena tidak ada parameter atau bobot yang dipelajari di dalamnya. Oleh karena itu, terkadang lapisan

aktivasi diabaikan dari diagram arsitektur jaringan sebab diasumsikan bahwa aktivasi segera mengikuti proses konvolusi[11]. Peran utama dari lapisan *pooling* ditujukan untuk mengecilkan ukuran spasial (lebar dan tinggi) secara bertahap dari data *input*[12]. Dengan cara ini, jumlah parameter dan komputasi dalam jaringan dapat dikurangi. Selain itu, lapisan *pooling* juga membantu dalam mengontrol *overfitting*. Ada beberapa teknik dalam *pooling* layer yakni *average-pooling* dan *max-pooling*, dan teknik yang paling umum adalah *max-pooling*[6]. *Max-pooling* menghitung dan hanya menampilkan maksimum tambalan lokal (biasanya 2 x 2 atau 3 x 3) unit *output* dalam *feature map*. Dengan demikian dapat mengurangi dimensi representasi fitur dan membuat *invariant* untuk pergeseran kecil dan *distorsi* pada input[13] Pemaparan di atas menjelaskan mengenai metode CNN yang akan dimanfaatkan dalam penelitian ini.

Tujuan utama dari studi ini adalah untuk merancang suatu sistem klasifikasi yang dapat mengidentifikasi penyakit antraknosa pada buah cabai merah besar dengan menggunakan metode *Convolutional Neural Network* (CNN). Harapannya, sistem ini akan memberikan dukungan kepada petani cabai merah besar dalam mendeteksi dan mengambil langkah pencegahan penyakit antraknosa pada tahap awal. Manfaat dari penelitian ini yaitu, memberikan wawasan baru mengenai penerapan teknik *Convolutional Neural Network* (CNN) dalam mengklasifikasikan penyakit antraknosa pada buah cabai merah besar, menghasilkan solusi praktis yang dapat membantu para petani cabai merah besar dalam mendeteksi dan mencegah penyakit antraknosa dengan tingkat ketepatan dan efisiensi yang tinggi, serta memberikan masukan berharga bagi para pengembang aplikasi pertanian dalam merancang sistem klasifikasi penyakit tanaman lainnya menggunakan metode CNN, yang berpotensi meningkatkan efektivitas dalam mencegah dan mengatasi penyakit pertanian.

Berdasarkan tinjauan pustaka, banyak peneliti saat ini memanfaatkan metode CNN untuk melakukan klasifikasi pada citra penyakit tanaman. Beberapa penelitian terkait dengan topik ini adalah sebagai berikut: Fitra Maulana & Rochmawati (2019), mengembangkan arsitektur CNN untuk mengklasifikasikan citra buah dan

mendapatkan hasil akurasi yang sangat baik[14]. Tsany Rakha Dzaky (2021), melakukan deteksi penyakit tanaman cabai menggunakan CNN dan menghasilkan akurasi yang cukup tinggi yaitu 80%, namun akurasi tersebut dapat ditingkatkan menggunakan teknik augmentasi data[2]. Anggraeni dkk. (2022), melakukan penelitian untuk klasifikasi penyakit tanaman cabai untuk menjaga kualitas cabai agar tidak mengalami penurunan hasil produksi di setiap tahunnya, namun hasil akurasi yang didapatkan terbilang kecil karena kesalahan yang disebabkan oleh sampel data yang bebas[15]. Savira Anggita Sabrina dan Wikky Fawwaz Al Maki (2022), membangun sistem klasifikasi CNN untuk klasifikasi penyakit tanaman kopi robusta dan mendapatkan hasil yang sangat baik dengan menggunakan dua algoritma optimasi yaitu adam dan *RMSprop*[16]. Errissya Rasywir, Rudolf Sinaga, dan Yovi Pratama, (2020), menerapkan metode CNN untuk sistem diagnosis penyakit tanaman sawit dan mendapatkan hasil akurasi yang baik dengan berkat penggunaan metode yang tepat[17]. Penelitian ini berbeda dari penelitian Tsany Rakha Dzaky (2021), karena penelitian ini tidak hanya mendeteksi penyakit tanaman cabai, tetapi juga mengklasifikasikan penyakit antraknosa pada buah cabai merah besar. Penelitian ini juga berbeda dari penelitian Anggraeni dkk. (2022), karena penelitian ini menggunakan data yang lebih valid dan akurat, serta menggunakan algoritma optimasi *Nadam* yang memberikan hasil terbaik.

Bagaimana penerapan *Convolutional Neural Network* (CNN) dalam pengembangan sistem klasifikasi dapat berkontribusi dalam proses deteksi dan klasifikasi penyakit pada tanaman cabai, khususnya dalam mengidentifikasi penyakit antraknosa pada buah cabai merah besar? Peneliti berhipotesis bahwa penerapan *Convolutional Neural Network* (CNN) dalam sistem klasifikasi akan menghasilkan tingkat akurasi yang signifikan dalam identifikasi dan klasifikasi penyakit antraknosa pada buah cabai merah besar. Dengan melakukan pengumpulan dataset gambar yang mencakup gejala penyakit dan melatih model CNN secara optimal, peneliti percaya bahwa sistem klasifikasi akan mampu menghasilkan prediksi yang tepat dan efisien. Keberhasilan ini diharapkan dapat memberikan dukungan berharga bagi petani dalam upaya pencegahan kerugian akibat serangan penyakit pada tanaman cabai.

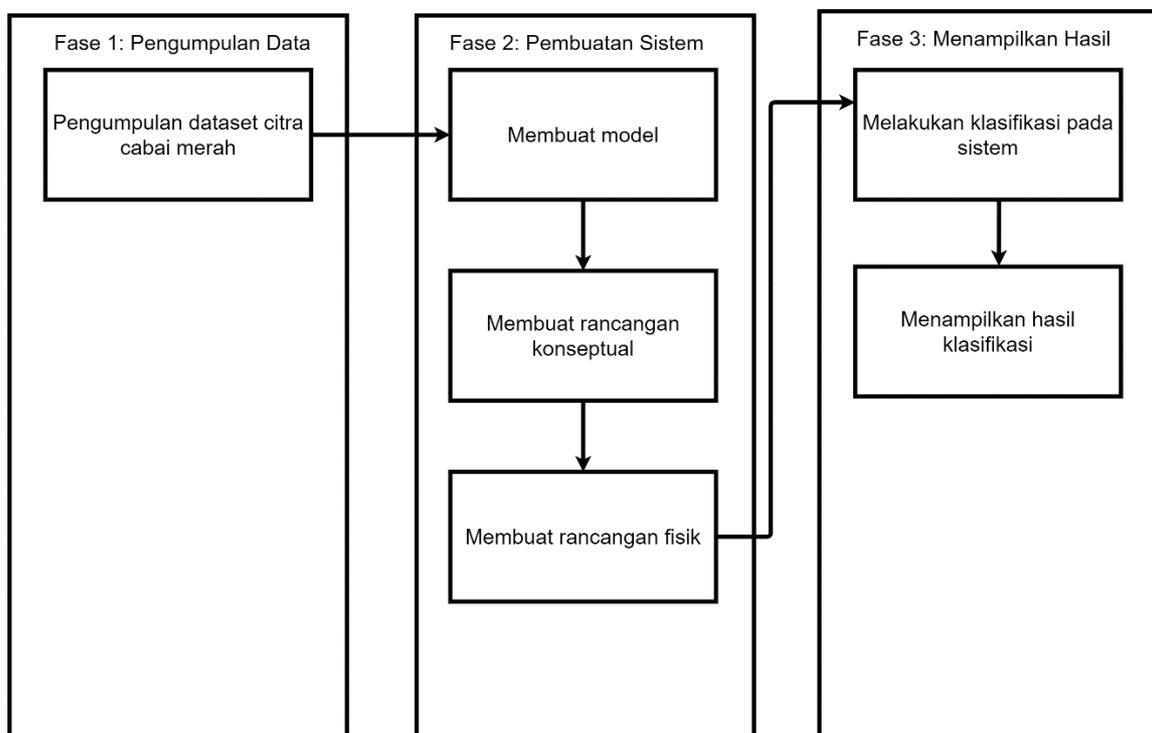
2. METODE PENELITIAN

Umumnya, metode yang diterapkan pada penelitian ini dijelaskan dalam diagram alur yang ditunjukkan pada Gambar 2.

2.1 Pengumpulan Data

Data citra cabai merah diperoleh dari petani pemilik kebun cabai merah. Petani pemilik kebun juga dapat disebut sebagai pakar dalam cabai merah karena mengerti banyak mengenai penyakit yang menyerang cabai merah. Data yang diperoleh berupa citra cabai merah yang normal atau sehat dan citra cabai merah yang

terkena penyakit antraknosa. Data diperoleh dengan melakukan survei langsung ke kebun cabai merah dan melakukan wawancara kepada pemilik kebun. Pengambilan data dilakukan di kebun cabai di Desa Widoro, Kelurahan Triharjo, Sleman, Yogyakarta. Total data yang diperoleh sebanyak 1000 data, yaitu 500 data citra cabai normal dan 500 data citra cabai antraknosa. Serta terdapat 500 tambahan data lainnya yang berisi citra dari sayur kacang panjang, buncis, tomat, dan wortel untuk klasifikasi ketika inputan testing bukan buah cabai. Data lain ini di dapatkan pada website *duckduck.go* melalui scrapping image. Total data yang digunakan untuk sistem klasifikasi ini adalah 1500 data.



Gambar 2. Tahapan Penelitian

2.2 Pembuatan Sistem

Tahap ini berfokus untuk membangun sistem. Di mulai dari membuat model, kemudian membuat rancangan konseptual pada sistem dan membuat perancangan fisik. Tabel 1 merupakan model CNN yang digunakan dalam membuat sistem klasifikasi. Arsitektur CNN dibangun menggunakan *Keras/Tensorflow* untuk melakukan ekstraksi atribut pada gambar dengan model *sequential*[7,18].

Table 1 Model CNN

Layer (type)	Output Shape	Param #
--------------	--------------	---------

conv2d (Conv2D)	(None, 148, 148, 32)	896
max_pooling2d (MaxPooling2D)	(None, 74, 74, 32)	0
conv2d_1 (Conv2D)	(None, 72, 72, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(None, 36, 36, 64)	0
conv2d_2 (Conv2D)	(None, 34, 34, 32)	18464
max_pooling2d_2 (MaxPooling2D)	(None, 17, 17, 32)	0
flatten (Flatten)	(None, 9248)	0
dense (Dense)	(None, 200)	1849800
dropout (Dropout)	(None, 200)	0
dense_1 (Dense)	(None, 500)	100500

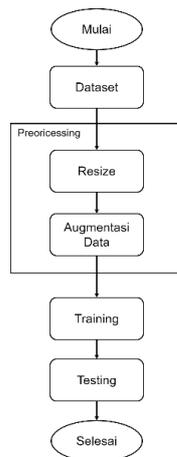
dropout_1 (Dropout)	(None, 500)	0
dense_2 (Dense)	(None, 3)	1503

Total params: 1,989,659

Trainable params: 1,989,659

Non-trainable params: 0

Rancangan konseptual yang digunakan untuk melakukan klasifikasi dapat dilihat pada *flowchart* sistem gambar 3. Pada proses *dataset* dilakukan proses *import dataset* ke sistem dari *dataset* yang ada pada direktori untuk dilakukan *training* pada sistem. Setelah di *import* kemudian dilakukan *preprocessing* pada *dataset*.



Gambar 3 *Flowchart* Sistem

Proses *preprocessing* dilakukan guna meningkatkan mutu gambar, dengan tujuan mempermudah dan mendorong kemampuan sistem dalam mengenali objek. *Preprocessing* dilakukan melewati dua tahap, yakni tahap *resize* dan tahap augmentasi data[7,19]. *Resize* dilakukan untuk mengubah ukuran citra agar sama satu sama lain baik secara *vertical* maupun *horizontal*. *Preprocessing* dimulai dengan mengubah skala intensitas gambar untuk memastikan bahwa nilai piksel berada dalam kisaran 0 hingga 1, dengan menggunakan faktor pengali sebesar $1/255$. Selanjutnya, dilakukan pengaturan untuk merotasi gambar dalam rentang 0 hingga 30 derajat. Setelah itu, dilakukan pengaturan untuk efek shear (geser) pada gambar, di mana gambar dapat digeser hingga 0.3 dalam rentang tertentu. Selanjutnya, untuk mengatasi area kosong yang mungkin muncul akibat transformasi sebelumnya, digunakan pendekatan '*nearest*' untuk mengisi area tersebut dengan piksel terdekat. Kemudian, dilakukan pengaturan untuk menggeser gambar secara *horizontal* dan *vertikal* hingga 0.2 dari ukuran gambar asli. Terakhir, dilakukan pengaturan untuk efek perbesaran pada gambar, di mana gambar

dapat diperbesar hingga 0.1 kali dari ukuran aslinya. Semua langkah ini bertujuan untuk menciptakan variasi dalam data pelatihan, sehingga model dapat lebih baik dalam mengenali berbagai variasi gambar selama proses pelatihan. Hasil dari proses *preprocessing* yaitu citra baru yang telah melalui proses *resize* dan augmentasi[19]. Citra baru yang dihasilkan kemudian digunakan untuk proses *training*.

Pada proses pelatihan (*training*) dilakukan proses pembelajaran pada data citra. Pada tahap pelatihan, dataset dipartisi menjadi dua bagian, yakni data *training* dan data validasi, dengan perbandingan 80% sebagai data pelatihan dan 20% sebagai data validasi[20]. Dalam pelatihan, langkah pertama adalah menetapkan ukuran target gambar, yang akan mengubah setiap gambar menjadi dimensi 150x150 piksel. Selanjutnya, *batch size* ditentukan, dan dalam konteks ini, digunakan nilai 40 untuk data pelatihan dan 10 untuk data validasi dari *dataset* yang tersedia. Langkah terakhir yang dilakukan adalah menentukan mode klasifikasi, yang diatur sebagai "*categorical*" karena *dataset* melibatkan lebih dari dua kelas. Proses pengaturan mode klasifikasi ini akan menghasilkan label-label dalam format *one-hot encoding*, yang memungkinkan representasi yang tepat dari berbagai kelas yang ada. Hasil dari proses testing berupa model yang akan disimpan untuk digunakan dalam proses testing.

Pada proses klasifikasi (*testing*) dilakukan pengujian berupa proses klasifikasi pada citra buah cabai baru dengan menggunakan model yang tersimpan dari hasil *training* yang telah dilakukan sebelumnya[21]. Proses klasifikasi dapat membedakan antara buah cabai merah besar yang normal dan yang terkena penyakit antraknosa dari gambar *inputan*. Proses dimulai dengan mengubah ukuran gambar cabai merah besar menjadi 150x150 piksel dan normalisasi intensitas piksel. Selanjutnya, model *Convolutional Neural Network* (CNN) yang telah dilatih akan menganalisis gambar dan menghasilkan probabilitas untuk kelas "normal" atau "antraknosa". Sistem akan memilih kelas dengan probabilitas tertinggi untuk menentukan status buah cabai merah besar tersebut[14]. Hasil klasifikasi kemudian ditampilkan bersama dengan gambar dan label yang relevan. Dengan demikian, sistem ini

menggunakan analisis fitur melalui model CNN untuk mengenali kondisi buah cabai merah besar dari citra *inputan*.

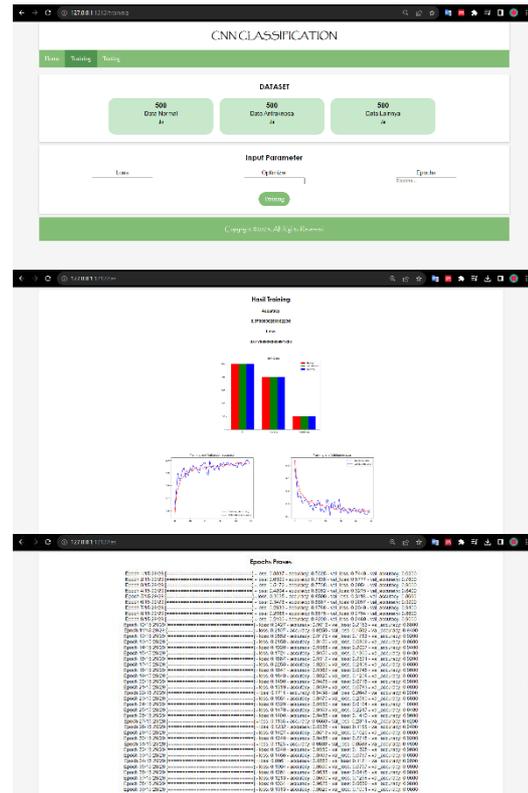
Rancangan fisik atau antar muka yang telah dibuat untuk sistem klasifikasi ini memiliki tiga menu, yaitu menu *home* (halaman utama), menu *training*, dan menu *testing* (halaman klasifikasi). Halaman utama pada gambar 4 terdapat *display* dua gambar yang terdiri dari gambar cabai normal dan cabai antraknosa sebagai sampel *dataset*, serta terdapat dua tombol untuk ke halaman *training* dan *testing*.



Gambar 4. Halaman Home

Halaman *training* pada gambar 5 berisi informasi mengenai jumlah *dataset* yang terdapat pada sistem yang akan digunakan untuk *training*. Terdapat tiga *form* untuk mengisi parameter ketika akan melakukan *training*, yaitu *form* parameter *loss*, *form* parameter *optimizer*, dan *form* untuk jumlah *epochs* yang akan digunakan, serta terdapat tombol *training* untuk memulai melakukan proses *training*.

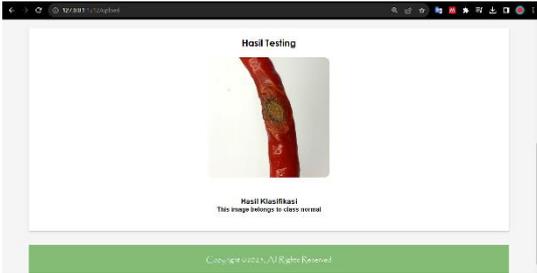
Hasil dari pelatihan akan muncul pada bawah halaman *form* dan tombol *training* setelah dilakukan *training* data. Pada gambar 5 hasil *training* terdapat nilai akurasi dan *loss*, kemudian terdapat *plotting* hasil *splitting* data yang digunakan serta grafik dari akurasi dan *loss*. Setelah itu pada gambar 5 juga terdapat *result* dari proses *epochs*.



Gambar 5. Halaman Training, Form Input, Hasil, dan Result Epochs

Halaman *testing* pada gambar 6 berisi informasi mengenai jumlah *dataset* yang terdapat pada sistem. Terdapat *form* yang digunakan untuk menginputkan gambar baru yang akan dilakukan klasifikasi dan tombol *testing* untuk memulai klasifikasi. Pada gambar 6 juga menunjukkan hasil *testing* atau klasifikasi dari gambar baru yang telah *diinputkan*. Sebuah gambar dengan teks hasil klasifikasi di bawahnya akan muncul sebagai bukti bawah gambar yang *diinputkan* sudah benar.





Gambar 6. Halaman Testing *form input* gambar dan hasil *testing*

3. HASIL DAN PEMBAHASAN

Pengujian sistem melalui dua tahap yaitu *training* dan *testing*. Pada tahap *training*, *dataset* akan terbagi menjadi dua bagian, yakni sebagai data latih sejumlah 80% dan sebagai data validasi sejumlah 20%[20]. *Dataset* validasi digunakan untuk menguji apakah proses pelatihan mampu menyesuaikan diri dengan variasi dalam *dataset* atau tidak[18]. Pada tahap ini, *dataset* dimanfaatkan untuk melatih model klasifikasi. Kemudian, pada tahap *testing*,

digunakan 6 contoh data baru yang akan digunakan untuk menguji kinerja model terhadap data yang belum pernah dilihat sebelumnya. Hal ini bertujuan untuk menguji sejauh mana kinerja model dalam menghadapi data yang tidak dikenal sebelumnya.

3.1 Training Dataset

Pelatihan *dataset* dilakukan dengan menggunakan berbagai macam algoritma optimasi yang berbeda namun dengan jumlah *epochs* yang sama yaitu 50 *epochs*. Algoritma optimasi dimanfaatkan dengan maksud untuk meningkatkan tingkat ketepatan dari model yang telah dibuat[21]. Algoritma optimasi tersebut yaitu *Adadelta*, *Adagrad*, *Adam*, *Adamax*, *Nadam*, *RMSprop*, dan *SGD*. Pelatihan menggunakan algoritma optimasi yang berbeda bertujuan untuk mencari model terbaik yang akan digunakan untuk *testing* data citra yang baru.

Table 2. Hasil Pelatihan Algoritma Optimasi

Parameter			Hasil	
Loss	Optimizer	Epochs	Loss	Accuracy
categorical_crossentropy	Adadelta	50	0.9515	0.5500
categorical_crossentropy	Adagrad	50	0.5204	0.7799
categorical_crossentropy	Adam	50	0.0968	0.9649
categorical_crossentropy	Adamax	50	0.1456	0.9399
categorical_crossentropy	Nadam	50	0.0645	0.9700
categorical_crossentropy	RMSprop	50	0.1345	0.9649
categorical_crossentropy	SGD	50	0.3535	0.8949

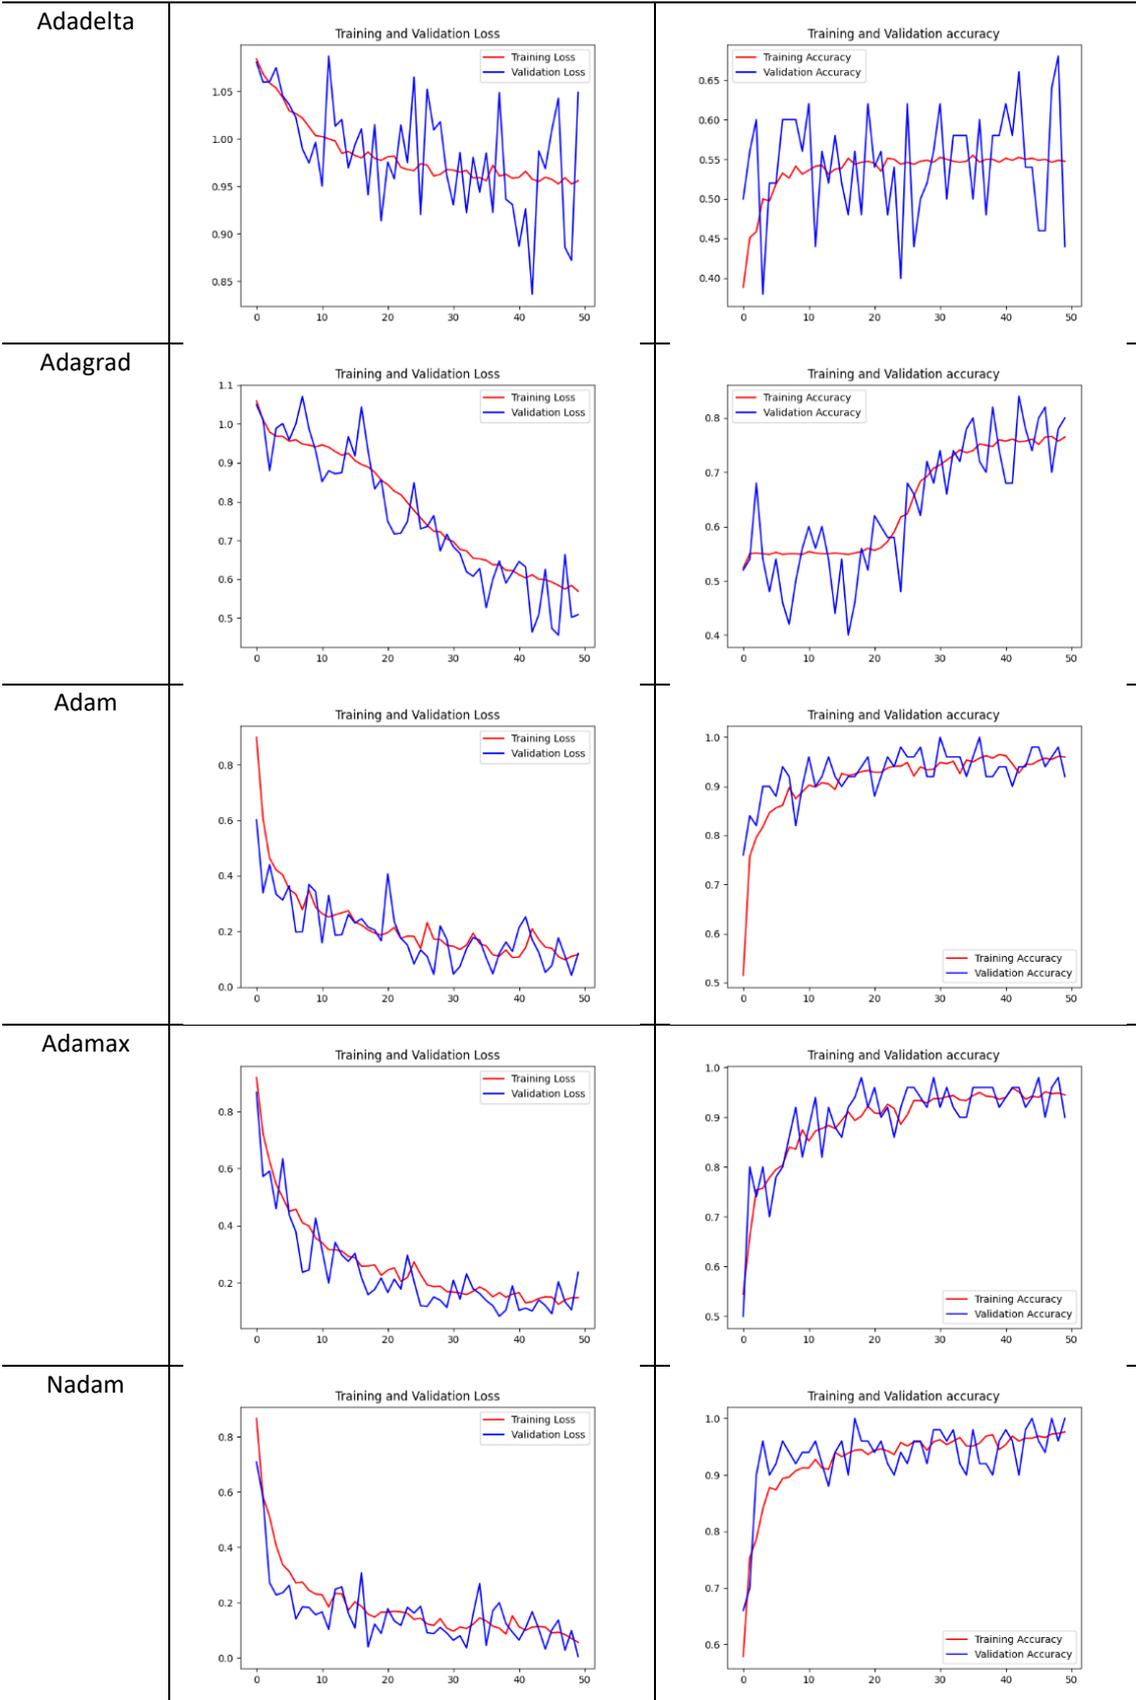
Pada eksperimen ini, dilakukan penerapan berbagai algoritma optimasi yang berbeda, dan tiap algoritma memiliki pendekatan yang berbeda dalam melakukan optimisasi parameter model[21]. Tujuan dari langkah ini adalah untuk membandingkan performa model selama proses pelatihan dengan berbagai algoritma optimasi, dengan tujuan memahami bagaimana algoritma tersebut mempengaruhi konvergensi model dan akurasi hasil. Pemilihan algoritma optimasi terbaik dilakukan

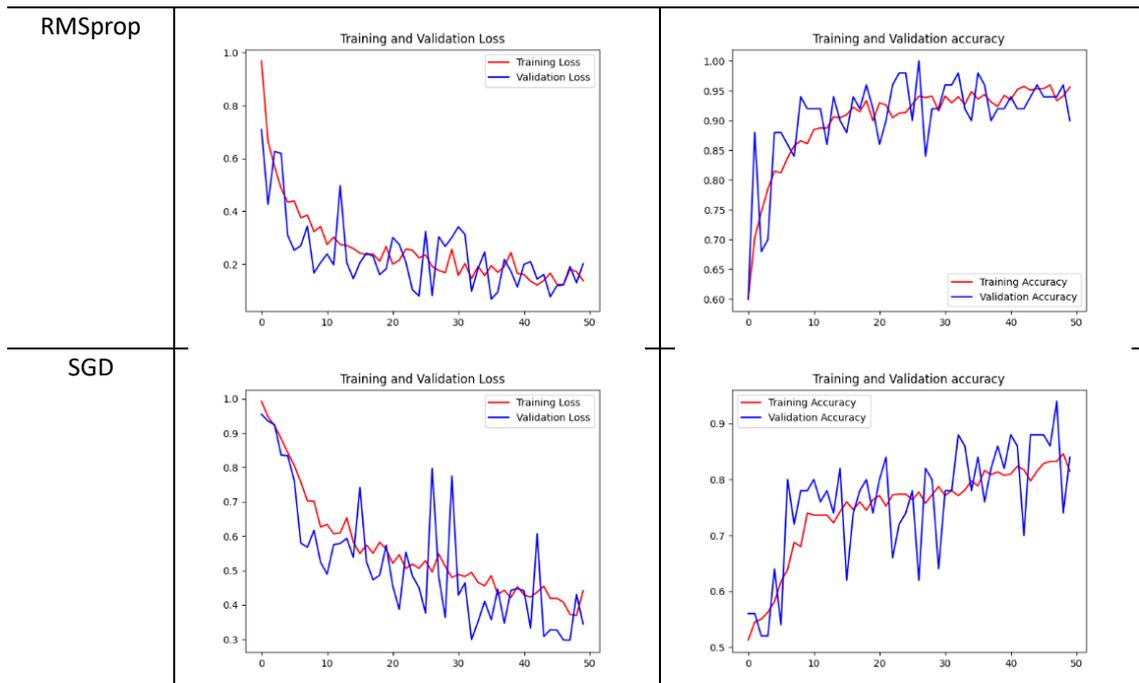
berdasarkan pertimbangan faktor-faktor seperti stabilitas dan akurasi model.

Eksperimen yang telah dilakukan mendapatkan hasil yang terdapat pada tabel 2. Dari hasil pengujian berdasarkan *parameter optimizer* (algoritma optimasi) dapat dilihat bahwa hasil dengan *loss* terkecil dan akurasi tertinggi diperoleh ketika menggunakan *parameter optimizer Nadam*. Pada pengujian ini menggunakan *categorical_crossentropy* karena data yang digunakan memiliki tiga kelas[14].

Table 3. Grafik Hasil Pelatihan Algoritma Optimasi

Optimizer	Grafik Loss	Grafik Accuracy
-----------	-------------	-----------------





Grafik performa setiap algoritma optimasi dapat dilihat pada tabel 3. Berdasarkan performa tersebut algoritma optimasi *Nadam* memberikan performa terbaik dengan menunjukkan grafik yang stabil dan tidak terlalu *overfitting* antara *training accuracy* dengan *validation accuracy*. Oleh karena itu, untuk melakukan klasifikasi terhadap citra baru menggunakan model dengan algoritma optimasi *Nadam*.

3.2 Testing

Testing atau pengujian klasifikasi dilakukan terhadap citra baru menggunakan model yang telah disimpan pada proses *training* sebelumnya[21]. Tahap *testing* pada penelitian ini menggunakan model dari hasil *training* dengan algoritma optimasi *Nadam* dan *epochs* sebanyak 50 *epochs*.

Table 4. Hasil Klasifikasi

Citra Baru		Hasil	
Citra Input	Class Input	Hasil Klasifikasi	Ketepatan Klasifikasi
	Antraknosa	<p>Hasil Testing</p> <p>Hasil Klasifikasi This image belongs to class antraknosa</p>	Benar

	<p>Antraknosa</p>	<p>Hasil Testing</p>  <p>Hasil Klasifikasi This image belongs to class antraknosa</p>	<p>Benar</p>
	<p>Antraknosa</p>	<p>Hasil Testing</p>  <p>Hasil Klasifikasi This image belongs to class antraknosa</p>	<p>Benar</p>
	<p>Antaknosa</p>	<p>Hasil Testing</p>  <p>Hasil Klasifikasi This image belongs to class normal</p>	<p>Salah</p>

	Normal	<p style="text-align: center;">Hasil Testing</p>  <p style="text-align: center;">Hasil Klasifikasi This image belongs to class normal</p>	Benar
	Normal	<p style="text-align: center;">Hasil Testing</p>  <p style="text-align: center;">Hasil Klasifikasi This image belongs to class normal</p>	Benar

Hasil klasifikasi pada tabel 4 menunjukkan bahwa, dari 6 data citra baru yang *diinputkan* terdapat 1 kesalahan prediksi. Data citra baru yang salah prediksi merupakan data citra antraknosa yang memiliki warna sedikit gelap sehingga penyakit antraknosa tidak terdeteksi karena warnanya sama dengan warna buahnya. Ketepatan dalam memprediksi cukup baik yaitu sebesar 83,33% dengan prediksi benar 5 data citra dari 6 data citra baru yang dilakukan klasifikasi. Hal ini menunjukkan bahwa model yang digunakan cukup baik dalam melakukan klasifikasi citra buah cabai merah.

Penelitian ini memberikan kontribusi dalam mengembangkan *Convolutional Neural Network* (CNN) guna mengklasifikasikan penyakit antraknosa pada cabai merah besar. Dampaknya mencakup manfaat nyata bagi petani dengan deteksi cepat penyakit,

berpotensi meningkatkan hasil panen, serta membantu lembaga pertanian, pengembang aplikasi, dan pemerintah dalam pengawasan penyakit tanaman serta inovasi pertanian berkelanjutan.

KESIMPULAN

Penelitian ini dilaksanakan dengan tujuan mengembangkan sistem klasifikasi untuk mendeteksi penyakit antraknosa pada buah cabai merah. Metode yang digunakan ialah *Convolutional Neural Network* (CNN), yang diharapkan dapat menjadi alat bantu efektif bagi petani dalam mendeteksi serta mencegah penyakit antraknosa pada tanaman cabai merah.

Dalam upaya mencapai tujuan tersebut, penelitian ini berhasil menghasilkan model CNN yang mampu membedakan antara buah cabai merah yang sehat dengan yang terinfeksi

penyakit antraknosa dengan tingkat akurasi yang signifikan. Kontribusi penting dari penelitian ini adalah penerapan teknologi Deep Learning dalam sektor pertanian, yang berpotensi memberikan inspirasi dan landasan bagi pengembangan metode serupa dalam deteksi penyakit pada tanaman lainnya. Keberhasilan sistem ini juga memberikan manfaat yang luas, termasuk bagi petani, lembaga pertanian, pengembang aplikasi pertanian, dan instansi pemerintah yang terkait dengan pertanian.

Dampak positif dari penelitian ini juga terlihat dalam upaya meningkatkan produktivitas dan keberlanjutan pertanian. Dengan adanya sistem klasifikasi yang dapat mendeteksi dini penyakit antraknosa pada cabai merah, petani dapat mengambil tindakan pencegahan yang tepat waktu, sehingga hasil panen dapat lebih terjaga dan risiko kerugian ekonomi dapat diminimalkan. Hasil penelitian ini juga memberikan panduan berharga bagi pengembang aplikasi pertanian yang berminat untuk mengadopsi metode CNN dalam mengembangkan sistem klasifikasi penyakit tanaman lainnya.

DAFTAR PUSTAKA

- [1] N. Prihatiningsih, H. A. Djatmiko, and E. Erminawati, "Komponen epidemi penyakit antraknosa pada tanaman cabai di kecamatan baturaden kabupaten Banyumas," *Jurnal Agro*, vol. 7, no. 2, pp. 203–212, Dec. 2020, doi: 10.15575/8000.
- [2] A. Tsany Rakha Dzaky, "Deteksi Penyakit Tanaman Cabai Menggunakan Metode Convolutional Neural Network," *Proceeding of Engineering*, vol. 8, no. 2, pp. 3039–3055, Apr. 2021.
- [3] B. Muslimin and P. Sugiartawan, "Implementasi Metode Certainly Factor Dalam Sistem Pakar Untuk Mengidentifikasi Penyakit Tanaman Lada," *Sintech Journal*, vol. 4, no. 2, pp. 195–201, 2021, [Online]. Available: <https://doi.org/10.31598>
- [4] S. Sisca Piay, A. Tyasdjaja, Y. Ermawati, and F. Rudi Prasetyo Hantoro, *Cabai Merah (Capsicum annuum .) L.* 2010.
- [5] O. Mongkolporn, *Capsicum*. CRC Press, 2019.
- [6] J. Imad, E. AYACHI Rachid, and B. Mohamed, "Automated Arabic News Classification using the Convolutional Neural Network," *International Journal on Electrical Engineering and Informatics*, vol. 15, no. 2, pp. 277–290, 2023, doi: 10.15676/ijeei.2023.15.2.7.
- [7] M. A. Rahman, M. R. Islam, M. A. H. Rafath, and S. Mhejabin, "CNN Based Covid-19 Detection from Image Processing," *Journal of ICT Research and Applications*, vol. 17, no. 1, pp. 99–113, Apr. 2023, doi: 10.5614/itbj.ict.res.appl.2023.17.1.7.
- [8] I. Ketut, G. Darma Putra, R. Fauzi, D. Witarsyah, P. Deva, and J. Putra, "Classification of Tomato Plants Diseases Using Convolutional Neural Network," *International Journal on Advanced Science Engineering Information Technology*, vol. 10, no. 5, pp. 1821–1827, 2020.
- [9] J. Vicky, F. Ayu, and B. Julianto, "Implementasi Pendeteksi Penyakit pada Daun Alpukat Menggunakan Metode CNN," *Prosiding Seminar Nasional Teknologi Dan Sains*, vol. 2, no. 1, pp. 155–162, 2023.
- [10] M. A. Wani, F. A. Bhat, S. Afzal, and A. I. Khan, *Advances in Deep Learning*, 1st ed., vol. 57. Springer Singapore, 2020. [Online]. Available: <http://www.springer.com/series/11970>
- [11] A. Rosebrock, *Deep Learning for Computer Vision with Python*, 1st ed. pyimagesearch, 2017.
- [12] S. Balasundaram *et al.*, "Automated detection and classification of breast cancer nuclei with deep convolutional neural network," *Journal of ICT Research and Applications*, vol. 15, no. 2, pp. 139–151, Oct. 2021, doi: 10.5614/itbj.ict.res.appl.2021.15.2.3.
- [13] B. Moons, D. Bankman, and M. Verhelst, *Embedded Deep Learning*, 1st ed. Switzerland: Springer International Publishing, 2019. doi: 10.1007/978-3-319-99223-5.
- [14] F. F. Maulana and N. Rochmawati, "Klasifikasi Citra Buah Menggunakan Convolutional Neural Network," *Journal of Informatics and Computer Science*, vol. 1, no. 2, pp. 104–108, 2019.

- [15] D. S. Anggraeni, A. Widayana, P. D. Rahayu, and C. Rozikin, "Metode Algoritma Convolutional Neural Network Pada Klasifikasi Penyakit Tanaman Cabai," *Satuan Tulisan Riset dan Inovasi Teknologi*, vol. 7, no. 1, pp. 73–78, Aug. 2022.
- [16] S. A. Sabrina and W. F. Al Maki, "Klasifikasi Penyakit pada Tanaman Kopi Robusta Berdasarkan Citra Daun Menggunakan Convolutional Neural Network," *Proceeding of Engineering*, vol. 9, no. 3, pp. 1919–1927, Jul. 2022.
- [17] E. Rasywir, R. Sinaga, and Y. Pratama, "Analisis dan Implementasi Diagnosis Penyakit Sawit dengan Metode Convolutional Neural Network (CNN)," *Jurnal Informatika dan Komputer*, vol. 22, no. 2, pp. 117–123, Sep. 2020, doi: 10.31294/p.v21i2.
- [18] D. I. Swasono, H. Tjandrasa, and C. Fatichah, "Classification of Air-Cured Tobacco Leaf Pests Using Pruning Convolutional Neural Networks and Transfer Learning," *International Journal on Advanced Science Engineering Information Technology*, vol. 12, no. 3, pp. 1229–1235, 2022.
- [19] N. Ibrahim *et al.*, "Klasifikasi Tingkat Kematangan Pucuk Daun Teh menggunakan Metode Convolutional Neural Network," *Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, no. 1, p. 162, Jan. 2022, doi: 10.26760/elkomika.v10i1.162.
- [20] I. Edo Hendrawan, M. Ilhamsyah, D. Yusup, U. Singaperbangsa Karawang, J. HSRonggo Waluyo, and P. KecTelukjambe Timur KabKarawang, "Klasifikasi Penyakit Powdery mildew Pada Ceri Manis Dengan Menggunakan Algoritma Convolutional Neural Network (CNN)," *Jurnal informasi dan Komputer*, vol. 10, no. 1, 2022.
- [21] E. Oktafanda, "Klasifikasi Citra Kualitas Bibit dalam Meningkatkan Produksi Kelapa Sawit Menggunakan Metode Convolutional Neural Network (CNN)," *Jurnal Informatika Ekonomi Bisnis*, vol. 4, no. 3, pp. 72–77, Aug. 2022, doi: 10.37034/infkeb.v4i3.143.