

IDENTIFIKASI JENIS PENYAKIT PADA TANAMAN CABAI RAWIT MENGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN) DI DESA BINTANG KECAMATAN SIDIKALANG

Todo Josafat Simanjuntak, Kana Saputra S, Hermawan Syahputra, Said Iskandar Al Idrus, Didi Febrian

Ilmu Komputer, Universitas Negeri Medan

Jalan Willem Iskandar, Pasar V Medan Estate, Percut Sei Tuan, Deli Serdang, Sumatera Utara, Indonesia

todosimanjuntak17@gmail.com

ABSTRAK

Cabai rawit merupakan jenis tanaman terna atau setengah merdu, memiliki tinggi sekitar 50-120 cm dengan umur bisa mencapai 3 tahun, Prospek cabai rawit cukup menjanjikan untuk memenuhi kebutuhan domestik dan ekspor Namun, produksi justru menurun. Salah satu faktor penyebab rendahnya produksi tanaman cabai adalah adanya gangguan penyakit yang menyerang. Identifikasi penyakit tanaman menjadi langkah penting dalam pemeliharaan dan perawatan, termasuk pada cabai rawit. metode yang digunakan dalam penelitian ini adalah Metode *CNN* (*Convolutional Neural Network*) dengan LeNet-5 sebagai arsitekturnya. Penelitian ini berhasil mengembangkan sistem berbasis *Convolutional Neural Network* (*CNN*) menggunakan arsitektur LeNet-5 untuk mengidentifikasi dan mengklasifikasi enam kelas penyakit pada tanaman cabai rawit di Desa Bintang, Kecamatan Sidikalang, dengan kinerja yang cukup baik ditunjukkan oleh akurasi 86%, presisi 87%, recall 86%, dan f1-score 86%. Untuk meningkatkan performa sistem, disarankan untuk melakukan eksperimen lebih lanjut dengan mengoptimalkan *hyperparameter* seperti learning rate dan jumlah epoch, memperluas dataset dengan variasi citra, mengeksplorasi arsitektur model yang lebih modern seperti AlexNet atau ResNet, serta menggunakan perangkat keras dengan spesifikasi yang lebih tinggi untuk efisiensi dan kecepatan pemrosesan yang lebih baik.

Kata kunci : Identifikasi Jenis Penyakit, Cabai Rawit, *Convolutional Neural Network*, Desa Bintang

1. PENDAHULUAN

Cabai merupakan tanaman sayuran yang memiliki nilai ekonomi tinggi dibandingkan dengan tanaman sayuran lainnya di pertanian. Harga cabai saat ini fluktuatif dan seringkali mengalami peningkatan yang signifikan di pasar, dipengaruhi oleh keterbatasan persediaan [1].

Cabai rawit merupakan jenis tanaman terna atau setengah merdu, memiliki tinggi sekitar 50-120 cm dengan umur bisa mencapai 3 tahun. Bunga pada cabai rawit muncul berpasangan atau lebih yang terdapat pada bagian ujung ranting, dengan posisi tegak dan mahkota bunga berwarna kuning kehijauan [2].

Prospek cabai rawit cukup menjanjikan untuk memenuhi kebutuhan domestik dan ekspor, dengan permintaan diperkirakan tumbuh 2,65% per tahun pada 2017–2021. Namun, produksi justru menurun 0,4% per tahun akibat penurunan luas panen sebesar 0,85% di periode yang sama [2].

Salah satu faktor penyebab rendahnya produksi tanaman cabai adalah adanya gangguan penyakit yang menyerang, seperti infeksi *Colletotrichum* sp yang menyebabkan antraknosa. Petani sangat dirugikan oleh penyakit ini karena menyerang bagian buah, sehingga buah yang rusak akibat serangan antraknosa akan mempengaruhi kualitas serta mengurangi kuantitas maupun mutu hasil produksi [3].

Ada beragam jenis penyakit pada tanaman cabai atau hama yang dapat menyerang tanaman cabai dalam satu tanaman, baik itu buah atau daun, seperti penyakit virus kuning yang menyebabkan daun cabai berubah menjadi kuning. Penyakit lain yang sering menyerang

adalah antraknosa pada buah, yang ditandai dengan munculnya bercak coklat kering seperti bekas terbakar pada buah cabai [4].

Klasifikasi adalah proses membangun model atau fungsi yang merepresentasikan konsep suatu data. Data dikumpulkan dan dikelompokkan ke dalam kategori tertentu yang disebut class, membentuk dataset pelatihan. Algoritma klasifikasi mempelajari dataset ini dalam proses pelatihan (training) untuk menghasilkan model yang mampu mengklasifikasikan data baru. [5]. Identifikasi penyakit tanaman menjadi langkah penting dalam pemeliharaan dan perawatan, termasuk pada cabai rawit. Jika penyakit tidak terdeteksi dan dibiarkan, kerusakan pada tanaman akan terus berlanjut dan memburuk.

Salah satu metode yang digunakan dalam klasifikasi adalah metode *CNN*. *Convolutional Neural Network* merupakan salah satu jenis algoritma deep learning yang dapat mengenali masukan gambar dan mengidentifikasi fitur objek pada gambar yang dapat digunakan sebagai ringkasan analisis gambar untuk membandingkan seluruh gambar yang tersedia [6].

Pada Penelitian ini, peran metode *CNN* sebagai metode dalam identifikasi dapat digunakan untuk mengklasifikasikan kondisi tanaman cabai dengan data latih yang memiliki label terhadap kondisi tanaman cabai, sehingga dapat mengklasifikasikan kondisi tanaman cabai.

2. TINJAUAN PUSTAKA

Pada penelitian sebelumnya [7] metode *CNN* juga diterapkan untuk melakukan klasifikasi penyakit

pada daun cabai rawit. Penelitian ini menggunakan total 1000 gambar daun cabai rawit yang terinfeksi penyakit yang diperoleh dari internet. Untuk meningkatkan kemampuan klasifikasi, digunakan pendekatan multi-arsitektur dengan memanfaatkan dua arsitektur *CNN*, yaitu SqueezeNet dan AlexNet. Hasil penelitian menunjukkan bahwa arsitektur SqueezeNet mencapai akurasi tinggi sebesar 90%, sementara AlexNet menghasilkan akurasi sebesar 85%, meskipun menggunakan variabel yang sama. Penelitian ini dilakukan dengan harapan bermanfaat bagi sektor pertanian khususnya pada komoditas hortikultura dan memberikan gambaran klasifikasi citra secara digital pada penyakit daun cabai dengan menggunakan CNN.

Kemudian pada penelitian [8] metode CNN kembali digunakan untuk mendeteksi penyakit pada tanaman padi. Dalam penelitian ini terdapat 3 kelas yang dideteksi dengan total 16.000 citra gambar sebagai data penelitian, hasil akurasi akhir yang didapat pada penelitian ini sebesar 99,66% dengan menerapkan konfigurasi optimizer adam, RMSprop, Nadam dan SGD (*Stochastic Gradient Descent*).

2.1. Pengolahan Citra Digital

Digital Image Processing adalah bagian ilmu yang berfokus pada teknik pengolahan gambar, baik gambar tidak bergerak/ diam seperti foto maupun gambar bergerak seperti video. Secara khusus, istilah "digital" merujuk pada proses pengolahan citra yang dilakukan secara digital menggunakan komputer [9].

Dalam melakukan pengolahan citra, data citra yang digunakan sebagai data masukan harus memiliki ukuran Panjang $\times$ Lebar $\times$ channel warna, Panjang dan Lebar menunjukkan ukuran citra dalam satuan piksel dan sebagai contoh citra yang memiliki 1 channel adalah citra *Grayscale* karena hanya menampilkan 1 jenis warna yaitu monokrom [10].

Citra merupakan representasi visual dari objek dua dimensi yang digunakan dalam berbagai bidang ilmu, seperti seni, penglihatan manusia, astronomi, dan teknik. Citra tersusun dari kumpulan piksel atau titik berwarna yang bersama-sama membentuk gambar dua dimensi [11]. Secara matematis, citra dapat dijelaskan sebagai suatu fungsi kontinu dari intensitas cahaya pada bidang dua dimensi.


2.2. Identifikasi Penyakit Tanaman Cabai Rawit

Proses pengidentifikasian jenis penyakit pada tanaman cabai rawit di desa Bintang difokuskan pada pengamatan penyakit yang mungkin muncul pada buah dan daun.

Dalam rangka mengatasi penyakit pada tanaman cabai rawit, penting dilakukan identifikasi penyakit pada tanaman tersebut. Hal ini bertujuan untuk memahami tanda-tanda penyakit, gejala-gejala yang muncul, dan mengetahui penyebab-penyakit yang dapat menyebabkan penyakit pada tanaman cabai rawit [12].

2.3. Algoritma Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan pengembangan dari metode *Multilayer Perceptron* (MLP) yang dirancang untuk mengolah data dalam skala besar dan khususnya untuk pemrosesan citra tiga dimensi. CNN memiliki kemampuan untuk menangkap informasi kontekstual yang terkandung di dalam citra seperti piksel yang saling berdekatan, yang berarti model CNN dapat melakukan ekstraksi ciri pada sebuah citra secara mandiri [13].



Gambar 1. Objek yang dilihat manusia dan komputer [14]

Dapat dilihat pada gambar 1, gambar pertama jika dengan mata manusia, maka akan sesuai dengan gambar aslinya. Sedangkan komputer melihat gambar yang dilihat mata manusia sebagai array dari angka-angka yang merupakan nilai piksel. Bentuk *array* sangat bergantung pada resolusi dan ukuran gambar. Sebagai contoh, sebuah gambar dengan format JPG memiliki resolusi 480 x 480, jika dituangkan dalam bentuk array akan berdimensi 480 x 480 x 3. Angka 3 ini adalah nilai RGB (*Red Green Blue*).

2.4. Arsitektur CNN

Arsitektur dalam *Convolutional Neural Network* (CNN) memiliki kemampuan untuk secara otomatis mengekstraksi fitur-fitur. Terdapat berbagai jenis arsitektur yang umum digunakan, seperti contohnya LeNet-5 (1998), AlexNet (2012), ZFNet (2013), VGGNet (2014), dan arsitektur yang populer digunakan lainnya.

Arsitektur LeNet-5 merupakan arsitektur yang dipilih didalam topik ini, Arsitektur LeNet-5 merupakan suatu model dengan berbagai lapisan berbasis *Convolutional Neural Network* (CNN) yang pertama kali diperkenalkan oleh Yann LeCun. LeNet-5 merupakan hasil pengembangan dari versi-versi sebelumnya, sehingga jumlah lapisannya lebih banyak dibandingkan dengan LeNet versi sebelumnya [15].

2.5. Algoritma Deep Learning

Deep Learning adalah cabang dari *Machine Learning* yang menggunakan metode *Neural Network* untuk menyelesaikan berbagai masalah. Salah satu algoritma *deep learning* yang sering digunakan adalah *Convolutional Neural Network* (CNN), yang efektif dalam mengatasi masalah klasifikasi citra [10]. Proses pembelajaran dalam *deep learning* dapat dilakukan dalam tiga pendekatan: terarah, semi-terarah, atau tak terarah [16].

2.6. Evaluasi

Metrik evaluasi merupakan instrumen yang digunakan untuk menilai performa suatu sistem atau model. Pengukuran ini berguna untuk menentukan sejauh mana sistem atau model mampu mengatasi suatu permasalahan atau meramalkan hasil yang diharapkan.

Hipotesis Kejadian	Kejadian Sebenarnya	
	P	N
	T	F
	True Positive	True Negative
	False Positive	False Negative

Gambar 2. metrik evaluasi

a. Akurasi

Akurasi digunakan untuk mengukur sejauh mana model dapat mengklasifikasikan data dengan benar.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN}$$

b. Presisi

Presisi berfokus pada seberapa banyak prediksi positif model yang benar.

$$Presisi = \frac{TP}{TP + FP}$$

c. Recall

Recall untuk mengukur sejauh mana model dapat mengidentifikasi semua kejadian positif.

$$Recall = \frac{TP}{TP + FN}$$


d. F-1 Score

F-1 Score merupakan harmonic mean atau rata-rata harmonic dari presisi dan recall, f1-score berguna untuk memberikan gambaran seimbang antara kedua metrik tersebut.

$$F1 - Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall}$$

3. METODE PENELITIAN

Penelitian ini berfokus pada pengembangan model *Convolutional Neural Network* (CNN) untuk mengidentifikasi jenis penyakit pada tanaman cabai rawit dengan tahapan penelitian dimulai dari pengumpulan data, praproses data, augmentasi data, pembagian data, implementasi algoritma CNN hingga evaluasi.



Gambar 3. Alur penelitian

3.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah data gambar. Pengumpulan data dilakukan dengan

mengambil gambar tanaman cabai rawit dalam berbagai kondisi, termasuk tanaman yang sehat atau tidak terinfeksi penyakit serta yang terinfeksi penyakit.

Pengumpulan data mencakup gambar tanaman cabai rawit yang dikategorikan ke dalam enam kelas, kelas tersebut terdiri dari dua kategori kelas tidak terinfeksi penyakit dan empat kategori kelas gambar yang terinfeksi penyakit.

3.2. Praproses Data

Praproses Data Merupakan penyesuaian ukuran gambar dan normalisasi nilai piksel untuk mempersiapkannya sebelum diberikan ke model CNN. Praproses membantu memastikan bahwa data memiliki format yang konsisten dan dapat diolah dengan baik oleh algoritma. Dengan kata lain, praproses dilakukan untuk mempersiapkan data mentah sebelum dimasukkan kedalam model CNN.

3.3. Augmentasi Data

Proses augmentasi data mencakup beberapa teknik seperti rotasi, pemotongan dan perubahan warna pada gambar untuk meningkatkan keanekaragaman data dan membantu model dalam mengenali pola dengan lebih baik. Proses augmentasi data bertujuan untuk meningkatkan variasi citra, sehingga dataset pelatihan menjadi lebih luas [17].

3.4. Pembagian Data

Pembagian data dilakukan dengan membagi 2 bagian dataset: bagian pertama sebagai data pelatihan (*training data*) dan bagian kedua sebagai data pengujian (*testing data*). Data pelatihan digunakan untuk melatih model CNN, sementara data pengujian digunakan untuk mengevaluasi seberapa baik model dapat mengidentifikasi penyakit yang terdapat pada gambar yang belum pernah dilihat.

3.5. Implementasi Algoritma CNN

Implementasi algoritma CNN dalam penelitian ini merujuk pada penerapan arsitektur LeNet-5 yang memanfaatkan *convolutional layer* dan *pooling layer*. CNN telah terbukti sebagai metode yang efektif dalam memproses data berdimensi tinggi seperti citra. *Convolutional layer* berperan dalam mengekstraksi fitur-fitur signifikan dari data input, sedangkan *pooling layer* digunakan untuk mengurangi dimensi spasial dari fitur-fitur tersebut, sehingga mengurangi kompleksitas komputasi dan mencegah *overfitting*.

3.6. Evaluasi

Proses evaluasi ini melibatkan penerapan metrik metrik evaluasi yang meliputi *accuracy*, *precision*, *recall* dan *F-1 score*, yang bertujuan untuk menilai efektivitas model CNN yang telah dikembangkan sebelumnya.

4. HASIL DAN PEMBAHASAN

4.1. Dataset Penelitian

Data dikumpulkan dari beberapa lahan perkebunan cabai rawit yang terletak di Desa Bintang Kecamatan Sidikalang. Dalam penelitian ini, data yang berhasil dikumpulkan berjumlah 720 citra dengan objek penelitian yaitu tanaman cabai rawit.

Peneliti mengambil gambar dari enam kategori kelas yaitu 2 kategori kelas yang tidak terinfeksi penyakit seperti: Buah tidak terinfeksi penyakit dan Daun tidak terinfeksi penyakit. dan 4 kategori kelas yang terinfeksi penyakit seperti: Penyakit keriting pada buah, Penyakit Antranoksa pada Buah, Penyakit Keriting pada daun, Penyakit virus kuning pada daun.

Tabel 1. Jumlah Dataset

Data Penyakit	Jumlah data gambar
Buah tidak terinfeksi penyakit	120
Penyakit Antranoksa pada Buah	120
Penyakit keriting pada buah	120
Daun tidak terinfeksi penyakit	120
Penyakit Keriting pada daun	120
Penyakit virus kuning pada daun	120
Total	720

4.2. Praproses Data

Praproses data dilakukan sebagai tahapan penyesuaian untuk mempersiapkan data dan memastikan bahwa data yang akan digunakan dalam analisis atau model berkualitas baik dan minim dari kesalahan.

a. Pembersihan data

Pembersihan data yang dimaksud adalah menghapus data yang tidak relevan dan menghapus data yang duplikat pada saat dilakukan pengambilan data gambar.

b. Pelabelan data

Pelabelan data dimaksudkan untuk setiap data gambar diberi label yang sesuai dengan kelas yang ingin dipelajari oleh model. Artinya, jika gambar 1 merupakan gambar penyakit antranoksa pada buah, maka diberi label “Buah terinfeksi penyakit antranoksa”, begitu juga dengan kelas penyakit lain.



Gambar 4. Contoh pelabelan data untuk buah terinfeksi penyakit antranoksa


c. Organizing Data

Organizing Data atau Pengorganisasian data yang dimaksud adalah data gambar dikelompokkan kedalam folder berdasarkan kelas penyakit. Pada penelitian ini terdapat 6 kelas data penyakit pada tanaman cabai rawit

yang mencakup buah dan daun, setiap kelas ini dikelompokkan kedalam 6 folder 33 yang masing-masing dinamai dengan nama penyakit tanaman cabai rawit tersebut.

4.3. Augmentasi

Augmentasi ini meliputi berbagai teknik seperti penerapan *shear range* untuk mengubah bentuk data, 34 *brightness range* untuk menyesuaikan tingkat kecerahan data, horizontal flip dan vertical flip untuk membalik data secara horizontal dan vertikal, serta *zoom range* untuk memperbesar atau memperkecil tampilan data.



Gambar 5. Contoh augmentasi data *shear*, *brigness*, *zoom*, vertical dan horizontal flip

Dengan teknik augmentasi, peneliti dapat meningkatkan jumlah dan keragaman data yang tersedia dari dataset yang ada, tanpa perlu melakukan pengumpulan data tambahan

Tabel 2. Jumlah dataset setelah diaugmentasi

Nama Penyakit	Jumlah data gambar
Buah tidak terinfeksi penyakit	240
Penyakit Antranoksa pada Buah	240
Penyakit keriting pada buah	240
Daun tidak terinfeksi penyakit	240
Penyakit Keriting pada daun	240
Penyakit virus kuning pada daun	240
Total	1440

4.4. Pembagian Data

Pembagian data merupakan langkah yang cukup penting dalam mengembangkan model dan tujuannya adalah untuk memastikan evaluasi kinerja model yang akurat dan dapat diandalkan. dataset yang tersedia dibagi menjadi dua set utama: data training dan data testing.

4.5. Implementasi Algoritma CNN

Implementasi algoritma CNN dengan modifikasi pada arsitektur LeNet-5 melibatkan dua lapisan utama: *Convolutional Layer* dan *Pooling Layer*.

Convolutional Layer berfungsi mendeteksi fitur lokal dalam gambar melalui penerapan filter atau kernel, yang menghasilkan peta fitur (*feature map*). Setelah melalui *Convolutional Layer*, *feature map*

diproses oleh *Pooling Layer*, yang mengurangi dimensi peta fitur dengan *subsampling* menggunakan operasi *max pooling*.

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 126, 126, 16)	448
max_pooling2d (MaxPooling2D)	(None, 42, 42, 16)	0
conv2d_1 (Conv2D)	(None, 40, 40, 32)	4640
max_pooling2d_1 (MaxPooling2D)	(None, 13, 13, 32)	0
conv2d_2 (Conv2D)	(None, 11, 11, 64)	18496
flatten (Flatten)	(None, 7744)	0
dropout (Dropout)	(None, 7744)	0
dense (Dense)	(None, 120)	929400
dropout_1 (Dropout)	(None, 120)	0
dense_1 (Dense)	(None, 84)	10164
dropout_2 (Dropout)	(None, 84)	0
dense_2 (Dense)	(None, 6)	510


Gambar 6. Model Summary LeNet-5 Modified

4.6. Training Model CNN

Seluruh data dilatih menggunakan jumlah *epoch* yang diperlukan, dimana semakin banyak data yang diterapkan, maka semakin banyak data yang akan dilatih. Dalam penelitian ini, proses pelatihan menerapkan parameter pembelajaran dengan total jumlah sebanyak 100 *epoch*.

Epoch 1/100	33/33	10s 279ms/step - loss: 1.8175 - accuracy: 0.1609 - val_loss: 1.7839 - val_accuracy: 0.1899
Epoch 2/100	33/33	9s 260ms/step - loss: 1.7866 - accuracy: 0.2013 - val_loss: 1.7813 - val_accuracy: 0.1860
Epoch 3/100	33/33	9s 287ms/step - loss: 1.7782 - accuracy: 0.2225 - val_loss: 1.7714 - val_accuracy: 0.3023
Epoch 4/100	33/33	8s 237ms/step - loss: 1.7661 - accuracy: 0.2380 - val_loss: 1.7604 - val_accuracy: 0.2287
Epoch 5/100	33/33	9s 269ms/step - loss: 1.7520 - accuracy: 0.2534 - val_loss: 1.7431 - val_accuracy: 0.3915
Epoch 6/100	33/33	9s 287ms/step - loss: 1.7350 - accuracy: 0.2823 - val_loss: 1.7262 - val_accuracy: 0.3256
Epoch 7/100	33/33	9s 269ms/step - loss: 1.7217 - accuracy: 0.2678 - val_loss: 1.6851 - val_accuracy: 0.1783
Epoch 8/100	33/33	8s 254ms/step - loss: 1.6910 - accuracy: 0.3073 - val_loss: 1.6859 - val_accuracy: 0.2287
...		
Epoch 99/100	33/33	8s 238ms/step - loss: 0.4377 - accuracy: 0.8362 - val_loss: 0.5535 - val_accuracy: 0.8217
Epoch 100/100	33/33	9s 272ms/step - loss: 0.4734 - accuracy: 0.8112 - val_loss: 0.4079 - val_accuracy: 0.8876

Gambar 7. Hasil training model



Gambar 8. Grafik accuracy dan Loss selama proses training


Setelah selesai melakukan pelatihan atau training data, pada *epoch* 100/100, berdasarkan ambar 7, model menampilkan *training loss* sebesar 0.47 dan *training accuracy* sebesar 0.81, dalam hal ini terlihat bahwa model memiliki kemampuan yang cukup baik dalam memprediksi data latih dengan tingkat *loss* yang semakin menurun. Selain itu, pada data uji atau validasi didapatkan *validation loss* sebesar 0.40 dan *validation accuracy* sebesar 0.88. Hasil ini menunjukkan bahwa model mampu memprediksi data yang belum pernah dilihat sebelumnya dengan akurasi yang sangat baik.

4.7. Cross Validation

Tujuan utama dari teknik *cross validation* ini adalah untuk melakukan prediksi model dan memperkirakan seberapa akurat sebuah model prediktif ketika dijalankan dalam praktiknya [18]. Dalam hal ini dataset dibagi menjadi 3 model untuk diuji dan untuk diketahui kemampuan masing-masing model.

4.7.1. Model 70:30


Pada Model 70:30, 70% dari total data yang tersedia digunakan sebagai data *training*, yaitu data yang dipakai untuk melatih model. Sementara itu, 30% sisanya digunakan sebagai data *testing*, yang berfungsi untuk mengevaluasi kinerja model yang sudah dilatih.



Gambar 9. Perbandingan tingkat akurasi dan loss untuk model 70:30

4.7.2. Model 80:20


Kemudian pada model ini, 80% dari total data yang tersedia digunakan sebagai data *training*, yaitu data yang dipakai untuk melatih model. Demikian juga 20% sisanya digunakan sebagai data *testing*, yang berfungsi untuk mengevaluasi kinerja model yang sudah dilatih.



Gambar 10. Perbandingan tingkat akurasi dan loss untuk model 80:20

4.7.3. Model 90:10


Sama seperti kedua model lainnya, model ini menggunakan 90% dari total data yang tersedia digunakan sebagai data *training*, yaitu data yang dipakai untuk melatih model. Dan 10% sisanya digunakan sebagai data *testing*, yang berfungsi untuk mengevaluasi kinerja model yang sudah dilatih.



Gambar 11. Perbandingan tingkat akurasi dan loss untuk model 90:10

Berdasarkan plot akurasi dan loss yang telah ditampilkan pada masing-masing model sebelumnya, tahap berikutnya adalah melakukan *cross validation* terhadap model pelatihan yang telah dikembangkan. Proses ini, seperti yang ditunjukkan pada Gambar 22, dilakukan untuk menentukan model terbaik diantara ketiga model pelatihan tersebut.

4.8. Cross Validation Accuracy



Gambar 12. Cross Validation Accuracy


Pada gambar 11 terlihat bahwa grafik dengan garis biru menunjukkan akurasi pada data latih, sedangkan garis orange menunjukkan akurasi pada data uji. Hasil *cross validation* untuk *accuracy* dapat dilihat pada tabel 4 dibawah.

Tabel 3. Cross Validation Accuracy

Cross Validation Accuracy	Model	Tingkat Accuracy (%)	
		Training Accuracy	Validation Accuracy
	90:10	0.66	0.72
	80:20	0.86	0.90
	70:30	0.81	0.88

Pada tabel 3 terlihat bahwa tingkat akurasi tertinggi terlihat pada model 80:20 dimana pada data training mendapat tingkat akurasi sebesar 86% dan tingkat akurasi pada data data validation sebesar 90%.

4.9. Cross Validation Loss



Gambar 13. Cross Validation Loss

Pada gambar 12 dapat dilihat bahwa grafik dengan garis biru menunjukkan tingkat *loss* pada data latih, sedangkan garis orange menunjukkan tingkat *loss* pada data uji. Hasil *cross validation* untuk tingkat *loss* dapat dilihat pada tabel 5 dibawah.

Tabel 4. Cross Validation Loss

Cross Validation Loss	Model	Tingkat Loss (%)	
		Training Loss	Validation Loss
	90:10	0.81	0.69
	80:20	0.39	0.37
	70:30	0.47	0.40


Pada tabel 4 terlihat bahwa nilai *error* atau *loss* terendah untuk *validation loss* terlihat pada model 80:20 dimana mendapat tingkat *loss* pada data *training* sebesar 39% dan tingkat *loss* pada data data *validation* sebesar 37%%. Begitu juga dengan nilai *loss* tertinggi terdapat pada model 90:10, dimana nilai *loss* pada data *training* sebesar 81% dan data *validation* 69%.

Berdasarkan hasil *cross-validation* pada *accuracy* dan *loss*, dapat disimpulkan bahwa model 80:20 adalah model yang terbaik diantara kedua model lainnya karena menghasilkan akurasi terbaik dan memiliki nilai *loss* terendah dibandingkan dengan kedua model lainnya.

Selanjutnya, proses *validation* akan dilakukan pada data uji untuk mengevaluasi laporan *recall*, *precision*, dan *f1-score* dari model terhadap data tersebut.

4.10. Evaluasi

Evaluasi model sangat penting untuk memahami seberapa baik model tersebut berfungsi dalam memprediksi keluaran yang benar.



Gambar 14. Confusion Matrix pengujian model 80:20

Berikut adalah hasil dari *classification report* untuk metrik evaluasi *precision*, *recall*, *f1-score* serta *Accuracy* berdasarkan data confusion matrix pada gambar 25 diatas.

Tabel 5. Hasil Evaluasi untuk model 80:20

Class	Precision	Recall	f1-score	Support
0	0.85	0.94	0.89	48
1	0.86	0.75	0.80	48
2	0.88	0.90	0.89	48
3	0.96	0.94	0.95	48
4	0.75	0.92	0.82	48
5	0.92	0.73	0.81	48
Accuracy			0.86	288

Confusion matrix memberikan gambaran sangat jelas terkait performa model dengan menunjukkan jumlah prediksi benar dan salah untuk masing-masing kelas. Berdasarkan *confusion matrix* pada gambar 13, model mampu mengklasifikasikan sebagian besar kategori penyakit dan kondisi tanaman cabai dengan benar.

Dari total prediksi, model berhasil mengklasifikasikan 45 kasus Buah Terinfeksi Penyakit Antraknosa dengan benar, 36 kasus Buah Terinfeksi Penyakit Keriting, dan 44 kasus Daun Terinfeksi Penyakit Virus Kuning. Namun, terdapat beberapa kesalahan prediksi, seperti 8 kasus Buah Terinfeksi Penyakit Keriting yang salah diklasifikasikan sebagai Buah Terinfeksi Penyakit Antraknosa dan 13 kasus Daun Tidak Terinfeksi Penyakit yang salah diklasifikasikan sebagai Daun Terinfeksi Penyakit Virus Kuning.

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan sistem berbasis *Convolutional Neural Network (CNN)* menggunakan arsitektur LeNet-5 untuk mengidentifikasi dan mengklasifikasi enam kelas penyakit pada tanaman cabai rawit di Desa Bintang, Kecamatan Sidikalang, dengan kinerja yang cukup baik ditunjukkan oleh akurasi 86%, presisi 87%, recall 86%, dan f1-score 86%. Untuk meningkatkan performa sistem, disarankan untuk melakukan eksperimen lebih lanjut dengan mengoptimalkan hyperparameter seperti learning rate dan jumlah epoch, memperluas dataset dengan variasi citra, mengeksplorasi arsitektur model yang lebih modern

seperti AlexNet atau ResNet, serta menggunakan perangkat keras dengan spesifikasi yang lebih tinggi untuk efisiensi dan kecepatan pemrosesan yang lebih baik.

DAFTAR PUSTAKA

- [1] M. Anwar, Y. Kristian, and E. Setyati, "Classification of Chili Plant Diseases Equipped With Leaf and Fruit Image Segmentation Using Yolo V7," *J. Inf. Technol. Comput. Sci.*, vol. 6, no. 1, pp. 540–548, 2023.
- [2] S. Rosdiana, *Teknologi Budidaya Cabai rawit*, 2011th ed. Gorontalo: Balai Pengkajian Teknologi Pertanian Gorontalo, 2011.
- [3] P. T. Tropika, P. Proteksi, T. Jurusan, H. P. T. Fakultas, P. Ulm, and C. Author, "Intensitas Serangan Penyakit Antraknosa yang Disebabkan Oleh Colletotrichum sp. pada Tanaman Cabai Rawit dan Cabai Besar di Desa Karya Maju Kecamatan Marabahan Kabupaten Barito Kuala Nazwan Syah Bani Hasbi *, Helda Orbani Rosa, Elly Liestiany," vol. 4, no. 03, pp. 380–385, 2021.
- [4] O. S. Rahma and M. Anwar, "Jurnal Vocational Teknik Elektronika dan Informatika," *J. Vocat. Tek. Elektron. dan Inform.*, vol. 9, no. 1, pp. 1–8, 2021, [Online]. Available: <http://ejournal.unp.ac.id/index.php/voteknika/index>
- [5] D. Irfansyah, M. Mustikasari, and A. Suroso, "Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi," *J. Inform. J. Pengemb. IT*, vol. 6, no. 2, pp. 87–92, 2021, doi: 10.30591/jpit.v6i2.2802.
- [6] D. Iswanto and D. Handayani UN, "Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (CNN)," *J. Ilm. Univ. Batanghari Jambi*, vol. 22, no. 2, p. 900, 2022, doi: 10.33087/jubj.v22i2.2065.
- [7] F. A. Danendra, F. T. Anggraeny, and H. Maulana, "Klasifikasi Citra Penyakit Daun Cabai Rawit Dengan Menggunakan CNN Arsitektur AlexNet dan SqueezeNet," *Syntax J. Inform.*, vol. 12, no. 01, pp. 50–61, 2023.
- [8] A. A. Santosa, R. Y. N. Fu'adah, and S. Rizal, "Deteksi Penyakit pada Tanaman Padi Menggunakan Pengolahan Citra Digital dengan Metode Convolutional Neural Network," *J. Electr. Syst. Control Eng.*, vol. 6, no. 2, pp. 98–108, 2023, doi: 10.31289/jesce.v6i2.7930.
- [9] S. Ratna, "Pengolahan Citra Digital Dan Histogram Dengan Phytton Dan Text Editor Phycharm," *Technol. J. Ilm.*, vol. 11, no. 3, p. 181, 2020, doi: 10.31602/tji.v11i3.3294.
- [10] A. T. R. Dzaky, "Deteksi Penyakit Tanaman Cabai Menggunakan Metode Convolutional Neural Network," *e-Proceeding Eng.*, vol. 8, no. 2, pp. 3040–3055, 2021.
- [11] J. Jumadi, Y. Yupianti, and D. Sartika,

- “Pengolahan Citra Digital Untuk Identifikasi Objek Menggunakan Metode Hierarchical Agglomerative Clustering,” *JST (Jurnal Sains dan Teknol.*, vol. 10, no. 2, pp. 148–156, 2021, doi: 10.23887/jst-undiksha.v10i2.33636.
- [12] N. Imah, Yulistiana, and R. H. Pratiwi, “Inventarisasi dan Identifikasi Penyakit Pada Tanaman Cabai Rawit (*Capsicum frutescens* L.) Di Kebun Gaga Semanan,” *Biodidaktika Jurnal Biol. dan Pembelajarannya*, vol. 17, no. 1, pp. 17–29, 2022.
- [13] B. Widiyanto, E. Utami, and D. Ariatmanto, “Identifikasi Penyakit Tanaman Jagung Berdasarkan Citra Daun Menggunakan Convolutional Neural Network,” *Techno.Com*, vol. 22, no. 3, pp. 599–608, 2023, doi: 10.33633/tc.v22i3.8425.
- [14] R. Primartha and R. S. wahono, *algoritma machine learning*, Januari 2. Bandung: INFORMATIKA Bandung, 2021.
- [15] M. R. Alwanda, R. P. K. Ramadhan, and D. Alamsyah, “Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle,” *J. Algoritma.*, vol. 1, no. 1, pp. 45–56, 2020, doi: 10.35957/algoritme.v1i1.434.
- [16] R. A. Tilasefana and R. E. Putra, “Penerapan Metode Deep Learning Menggunakan Algoritma CNN Dengan Arsitektur VGG NET Untuk Pengenalan Cuaca,” *J. Informatics Comput. Sci.*, vol. 05, no. 1, pp. 48–57, 2023.
- [17] P. Sitompul, H. Okprana, A. Prasetyo, and G. Artikel, “Identifikasi Penyakit Tanaman Padi Melalui Citra Daun Menggunakan DenseNet 201 Identification of Rice Plant Diseases Through Leaf Image Using DenseNet 201 Article Info ABSTRAK,” *JOMLAI J. Mach. Learn. Artif. Intell.*, vol. 1, no. 2, pp. 143–150, 2022, doi: 10.55123/jomlai.v1i2.889.
- [18] H. Azis, P. Purnawansyah, F. Fattah, and I. P. Putri, “Performa Klasifikasi K-NN dan Cross Validation Pada Data Pasien Pengidap Penyakit Jantung,” *Ilk. J. Ilm.*, vol. 12, no. 2, pp. 81–86, 2020, doi: 10.33096/ilkom.v12i2.507.81-86.