

Analisis Kinerja CNN Dengan XceptionNet Dalam Klasifikasi Penyakit Daun Terong Berdasarkan Citra

Tirza Mesak^{1*}, Gracia Anasthasia¹, Muh. Syahlan Natsir², Muhammad Rusdi Rahman²

¹Teknik Informatika, Universitas Dipa Makassar, Makassar, Indonesia

²Universitas Dipa Makassar, Makassar, Indonesia

e-mail: ¹tirzamesak9363@gmail.com, ²graciaanasthasia17@gmail.com, ³sahlan@undipa.ac.id, ⁴rusdi.rahman@undipa.ac.id

Abstrak

Tanaman terong (Solanum melongena) merupakan salah satu komoditas hortikultura yang memiliki nilai ekonomi penting di Indonesia. Dalam proses budidayanya, tanaman terong sering mengalami berbagai jenis penyakit pada bagian daun yang dapat mengganggu proses fotosintesis dan menurunkan produktivitas tanaman. Identifikasi penyakit daun secara manual sering mengalami kesulitan karena beberapa jenis penyakit memiliki kemiripan pola visual sehingga sulit dibedakan secara akurat. Oleh karena itu, penelitian ini bertujuan untuk menganalisis kinerja Convolutional Neural Network (CNN) dengan arsitektur XceptionNet dalam melakukan klasifikasi penyakit daun terong berdasarkan citra. Dataset yang digunakan terdiri dari 1.400 citra dengan 7 kelas penyakit daun terong yang diperoleh dari Kaggle. Proses penelitian meliputi tahap pra-pemrosesan data, pelatihan model menggunakan pendekatan transfer learning, serta evaluasi model menggunakan metrik accuracy, precision, recall, dan F1-score. Hasil penelitian menunjukkan bahwa model CNN dengan arsitektur XceptionNet mampu melakukan klasifikasi penyakit daun terong dengan akurasi sebesar 83,57% serta menunjukkan performa yang cukup baik pada metrik evaluasi lainnya. Hasil ini menunjukkan bahwa metode yang digunakan memiliki potensi untuk dikembangkan sebagai sistem identifikasi penyakit tanaman berbasis citra secara otomatis.

Kata kunci—CNN, XceptionNet, Klasifikasi Citra, Penyakit Daun Terong, Deep Learning.

Abstract

Eggplant (Solanum melongena) is one of the horticultural commodities that has significant economic value in Indonesia. In the cultivation process, eggplant plants often experience various leaf diseases that can disrupt the photosynthesis process and reduce crop productivity. Manual identification of leaf diseases is often difficult due to the similarity of visual patterns among different disease classes, making accurate classification challenging. Therefore, this study aims to analyze the performance of a Convolutional Neural Network (CNN) using the XceptionNet architecture for classifying eggplant leaf diseases based on image data. The dataset used consists of 1,400 images with 7 disease classes, obtained from Kaggle. The research process includes data preprocessing, model training using a transfer learning approach, and model evaluation using several metrics, namely accuracy, precision, recall, and F1-score. The results show that the CNN model with the XceptionNet architecture achieves an accuracy of 83.57% and demonstrates good performance across other evaluation metrics. These results indicate that the proposed method has strong potential to be developed as an automated image-based plant disease identification system.

Keywords—CNN, XceptionNet, Image Classification, Eggplant Leaf Disease, Deep Learning.

1. PENDAHULUAN

Tanaman terong (*Solanum melongena* L.) merupakan salah satu komoditas hortikultura yang memiliki nilai ekonomi dan nilai gizi karena mengandung berbagai senyawa bioaktif, seperti senyawa *fenolik* dan *antosianin* yang berpotensi memberikan manfaat bagi kesehatan [1]. Oleh karena itu, upaya menjaga kualitas serta produktivitas tanaman terong menjadi hal yang penting agar hasil produksi dapat dipertahankan secara optimal.

Namun, dalam proses budidayanya, tanaman terong menghadapi berbagai kendala, salah satunya adalah serangan penyakit dan hama pada bagian daun. Beberapa gangguan yang dapat ditemukan pada tanaman terong meliputi *Cercospora leaf spot*, *Tobacco Mosaic Virus (TMV)*, little leaf, serangan *Epilachna beetle*, dan *two-spotted spider mite* [2]. Daun merupakan bagian tanaman yang penting dalam proses pertumbuhan sehingga gangguan penyakit pada daun dapat memengaruhi kesehatan tanaman dan berpotensi menurunkan kualitas maupun produktivitas hasil pertanian [2], [3].

Proses identifikasi penyakit tanaman secara konvensional umumnya dilakukan melalui pengamatan visual terhadap gejala yang muncul, seperti perubahan warna, tekstur, bentuk, maupun bercak pada permukaan daun. Akan tetapi, pemeriksaan secara manual memiliki beberapa keterbatasan karena membutuhkan waktu, tenaga, dan pengetahuan dari ahli, serta berpotensi menghasilkan kesalahan ketika gejala penyakit memiliki karakteristik visual yang hampir serupa [3]–[5]. Tantangan lainnya adalah variasi kondisi pencahayaan, latar belakang, kualitas citra, serta kemiripan visual antarkelas penyakit yang dapat mempersulit proses identifikasi [4], [5].

Perkembangan teknologi pengolahan citra digital, machine learning, dan deep learning memberikan peluang untuk mengatasi permasalahan tersebut melalui sistem klasifikasi penyakit tanaman secara otomatis berbasis citra [3]–[5]. Salah satu metode deep learning yang banyak digunakan dalam klasifikasi citra adalah *Convolutional Neural Network (CNN)*. CNN mampu melakukan proses ekstraksi fitur secara otomatis dari citra sehingga karakteristik seperti pola, tekstur, bentuk, dan informasi visual lainnya dapat dipelajari secara langsung selama proses pelatihan model [4], [5].

Penelitian sebelumnya telah memanfaatkan berbagai arsitektur CNN untuk klasifikasi penyakit tanaman. Noprisson [6], misalnya, menerapkan transfer learning menggunakan VGG16 untuk klasifikasi penyakit tanaman padi dan menunjukkan bahwa proses *fine-tuning* dapat meningkatkan performa model dibandingkan penggunaan VGG16 tanpa fine-tuning. Selain VGG16, penelitian lain telah membandingkan berbagai arsitektur CNN seperti *MobileNetV2* dan *Xception* dalam klasifikasi penyakit daun. Altabaji et al. [7] membandingkan LeafNet, Modified LeafNet, *MobileNetV2*, dan *Xception* pada klasifikasi penyakit daun padi dengan mempertimbangkan beberapa parameter pelatihan seperti *batch size*, *learning rate*, *optimizer*, *accuracy*, *precision*, *recall*, dan *F1-score*.

Penggunaan *Xception* pada klasifikasi penyakit tanaman juga telah menunjukkan potensi yang baik. Muslikh et al. [8] menggunakan pendekatan transfer learning berbasis *Xception* untuk pengenalan penyakit tanaman padi. Sementara itu, Abisha dan Bharathi [9] mengembangkan pendekatan hibrida *Xception-Random Forest* untuk klasifikasi multikelas penyakit pada daun tanaman. Berbagai penelitian tersebut menunjukkan bahwa arsitektur *Xception* dapat dimanfaatkan sebagai *feature extractor* maupun sebagai model klasifikasi berbasis *transfer learning* pada permasalahan pengenalan penyakit tanaman [7]–[9].

Xception merupakan arsitektur *deep convolutional neural network* yang dikembangkan dengan memanfaatkan *depthwise separable convolution*. Pada pendekatan ini, proses konvolusi dipisahkan menjadi *depthwise convolution* untuk memproses informasi spasial pada setiap kanal dan *pointwise convolution* untuk menggabungkan informasi antar kanal [10]. Pendekatan tersebut memungkinkan jaringan menggunakan parameter secara lebih efisien dibandingkan operasi konvolusi konvensional [10]. Penggunaan *depthwise separable convolution* pada klasifikasi penyakit tanaman juga telah diteliti dan menunjukkan bahwa pendekatan tersebut dapat mengurangi jumlah parameter model secara signifikan dengan tetap mempertahankan performa

klasifikasi yang kompetitif [11].

Meskipun berbagai penelitian telah menerapkan *CNN*, *VGG16*, *MobileNet*, *ResNet*, maupun *Xception* pada klasifikasi penyakit tanaman [3], [6]–[11], penelitian yang secara khusus mengkaji penerapan *Xception* pada klasifikasi penyakit daun terong masih relatif lebih terbatas dibandingkan penelitian pada tanaman padi dan tanaman lainnya. Penelitian terdahulu pada *Solanum melongena* telah menerapkan model deep learning seperti *AlexNet* dan *VGG16* untuk mengklasifikasikan beberapa jenis penyakit dan gangguan tanaman [2]. Kondisi tersebut memberikan peluang untuk mengkaji lebih lanjut penggunaan arsitektur *Xception* pada objek penyakit daun terong.

Selain pemilihan arsitektur, konfigurasi parameter pelatihan juga memiliki peranan penting terhadap performa model. Parameter seperti optimizer, learning rate, pembagian data, dan strategi optimalisasi dapat menghasilkan perbedaan performa pada model *CNN*. Suryani dan Natsir dari Universitas Dipa Makassar [12] menunjukkan bahwa penerapan hyperparameter tuning dan callback pada model *ConvNet* dapat meningkatkan performa model klasifikasi citra. Penelitian tersebut memperoleh validation accuracy sebesar 98,18% pada konfigurasi terbaiknya, yang menunjukkan pentingnya pemilihan konfigurasi pelatihan dalam optimalisasi model *CNN* [12].

Berdasarkan kajian tersebut, penelitian ini menerapkan arsitektur *Xception* untuk klasifikasi penyakit daun terong serta menganalisis pengaruh parameter pelatihan, khususnya optimizer dan learning rate, terhadap performa model. Aspek ini menjadi bagian penting dalam penelitian karena performa model deep learning tidak hanya ditentukan oleh arsitektur yang digunakan, tetapi juga oleh konfigurasi proses pelatihannya [7], [12].

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk menganalisis kinerja model *CNN* dengan arsitektur *Xception* dalam melakukan klasifikasi penyakit daun tanaman terong berdasarkan citra. Model dibangun menggunakan pendekatan transfer learning dengan memanfaatkan model yang telah dilatih sebelumnya sehingga proses pembelajaran dapat dilakukan secara lebih efektif pada dataset penyakit daun terong [7], [8]. Selanjutnya, performa model dievaluasi menggunakan beberapa metrik pengujian, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*, yang umum digunakan untuk mengevaluasi kemampuan model klasifikasi dalam mengenali serta membedakan kelas penyakit tanaman [4], [7].

2. METODE PENELITIAN


Penelitian ini menggunakan pendekatan eksperimental untuk menganalisis kinerja model *CNN* dengan arsitektur *XceptionNet* dalam klasifikasi penyakit daun terong.

2.1 Dataset

Dataset yang digunakan dalam penelitian ini merupakan dataset citra daun terong yang diperoleh dari *Kaggle*. Dataset tersebut berisi gambar daun terong yang telah memiliki label sesuai dengan jenis penyakit yang terdapat pada daun.

Dataset terdiri dari 7 kelas penyakit dengan distribusi data yang relatif seimbang, masing-masing kelas memiliki sekitar 200 citra.

Dataset ini terdiri dari 1.400 citra dan memiliki beberapa kelas penyakit daun yang digunakan sebagai data latih dan data uji dalam proses pelatihan model. Data latih digunakan untuk melatih model agar mampu mengenali pola penyakit pada daun, sedangkan data uji digunakan untuk mengevaluasi performa akhir dari model yang telah dilatih.



Gambar 1 Contoh dataset citra daun terong pada setiap kelas penyakit

2. 2 Pra-pemrosesan Data

Sebelum digunakan dalam proses pelatihan model, citra daun terong melalui beberapa tahap pra-pemrosesan, yaitu:

a. Normalisasi Piksel

Nilai piksel diubah ke rentang 0-1 untuk mempercepat proses pelatihan model.


b. Data Augmentation

Teknik seperti rotasi, *flipping*, dan pergeseran digunakan untuk meningkatkan variasi dataset dan mengurangi risiko *overfitting*.

2. 3 Arsitektur Model

Model klasifikasi yang digunakan dalam penelitian ini adalah XceptionNet, yang merupakan salah satu arsitektur CNN modern dengan konsep *Depthwise Separable Convolution*. Dalam penelitian ini digunakan pendekatan *Transfer Learning*, yaitu memanfaatkan model *XceptionNet* yang telah dilatih sebelumnya pada dataset besar, kemudian disesuaikan dengan dataset penyakit daun terong.

Pada proses transfer learning, layer awal dari model XceptionNet dibekukan (*freeze*) untuk mempertahankan fitur dasar yang telah dipelajari, sedangkan beberapa layer akhir dilakukan fine-tuning agar model dapat menyesuaikan dengan karakteristik dataset penyakit daun terong.



Gambar 2 Arsitektur XceptionNet

2. 4 Proses Pelatihan Model

Pada tahap ini dilakukan proses pelatihan model menggunakan dataset training yang telah dipersiapkan sebelumnya. Model dilatih dengan beberapa parameter pelatihan seperti:

- Optimizer: Adam*
- Output Layer: Softmax*
- Loss Function: Sparse Categorical Crossentropy*
- Epoch: 35*
- Batch Size: 16*
- Validation Split: 20%*
- Platform Pelatihan: Google Colab dengan TensorFlow dan Keras.*

Selama proses pelatihan berlangsung, model akan mempelajari pola visual dari citra daun yang berbeda untuk setiap kelas penyakit. Proses ini dilakukan secara berulang hingga model mampu mengenali karakteristik masing-masing penyakit dengan baik.

Pemilihan batch size sebesar 16 dilakukan untuk menyeimbangkan penggunaan memori dan stabilitas pelatihan model. Sementara itu, jumlah epoch sebanyak 35 dipilih berdasarkan hasil eksperimen awal yang menunjukkan bahwa model telah mencapai kondisi konvergen tanpa mengalami overfitting yang signifikan.

Selain itu, proses pelatihan juga dipantau menggunakan data validation untuk melihat perkembangan kinerja model selama proses training. Hasil pelatihan kemudian disimpan sebagai model terbaik yang akan digunakan pada tahap pengujian.

2. 5 Evaluasi Model

Setelah proses pelatihan selesai, model yang telah dilatih kemudian dievaluasi menggunakan data testing untuk mengetahui tingkat performa klasifikasi yang dihasilkan. Evaluasi dilakukan dengan menggunakan beberapa metrik pengukuran, yaitu:

- Accuracy*

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (1)$$

- Precision*

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

- Recall*

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

- F1-Score*

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Keterangan variable:

TP = *True Positive* (prediksi benar positif)

TN = *True Negative* (prediksi benar negatif)


FP = *False Positive* (prediksi positif tapi salah)

FN = *False Negative* (prediksi negatif tapi salah)

Selain itu, digunakan juga *Confusion Matrix* untuk melihat secara lebih rinci bagaimana model mengklasifikasikan setiap kelas penyakit daun terong. Melalui evaluasi ini dapat diketahui seberapa baik kemampuan model dalam membedakan setiap jenis penyakit berdasarkan citra daun.

3. HASIL DAN PEMBAHASAN

3.1 Perancangan Solusi



Gambar 3 Alur Perancangan Solusi

Gambar 3 memperlihatkan alur perancangan Solusi dalam penelitian ini, mulai dari pengumpulan data hingga evaluasi model. Secara ringkas, tahapan yang dilakukan adalah sebagai berikut:

3.2.1 Pengumpulan Data

Dataset yang digunakan dalam penelitian ini merupakan dataset citra daun terong yang diperoleh dari *Kaggle*. Dataset tersebut berisi gambar daun terong yang telah memiliki label sesuai dengan jenis penyakit yang terdapat pada daun, dan dataset ini terdiri dari 1.400 citra yang memiliki beberapa kelas penyakit daun.

3.2.2 Pra-pemrosesan Citra

Data citra yang terkumpul selanjutnya diproses agar model dapat menerima dan mengolahnya secara optimal:

- Augmentasi Data: diterapkan teknik augmentasi untuk memperkaya variasi data latih tanpa perlu menambah data baru secara manual. Augmentasi dilakukan menggunakan layer *Sequential* dari *TensorFlow Keras*. Augmentasi ini memodifikasi citra secara acak agar model tidak menghafal posisi objek dan lebih *robust* terhadap variasi kondisi input. Augmentasi dilakukan dengan beberapa transformasi, antara lain: *Random Flip* (membalik citra secara horizontal dan vertical) sehingga model dapat mengenali daun dari berbagai orientasi. *Random Rotation*, memutar citra secara acak sehingga 0.2 radian ($\sim 11^\circ$) untuk membuat model tahan terhadap variasi sudut objek. *Random Zoom*, memperbesar atau memperkecil secara acak 20% agar model adaptif terhadap skala objek yang berbeda.

```

# untuk melakukan data augmentation dengan memodifikasi gambar secara acak
data_augmentation = tf.keras.Sequential([
    layers.RandomFlip("horizontal_and_vertical"),
    layers.RandomRotation(0.2),
    layers.RandomZoom(0.2),
    layers.RandomContrast(0.1),
])
  
```

Gambar 4 Kode Augmentasi

- Normalisasi: Setelah augmentasi, citra juga dinormalisasi dengan mengubah nilai pikselnya ke skala 0-1 (dilakukan dengan parameter `preprocess_input`) mengubah skala piksel dari 0-255 menjadi rentang -1 hingga 1.

```

inputs = tf.keras.Input(shape=(299, 299, 3))
x = data_augmentation(inputs) # Menambahkan augmentasi di awal
x = tf.keras.applications.xception.preprocess_input(x)
x = base_model(x, training=False)
x = layers.GlobalAveragePooling2D()(x)
x = layers.Dropout(0.6)(x) # Dinaikkan ke 0.6 untuk mengurangi ove
outputs = layers.Dense(7, activation='softmax')(x)
#untuk membangun ulang model

model = tf.keras.Model(inputs, outputs)

```

Gamabr 5 Kode Normalisasi

Dengan rangkaian tahapan diatas, data inilah yang kemudian digunakan dalam proses pelatihan model CNN. Jumlah data yang digunakan dalam penelitian ini menggunakan 1.400 data, terdiri dari 7 kelas penyakit tanaman daun terong. Dibagi menjadi data training 80% dan data testing 20% untuk memastikan model CNN dapat belajar dan dievaluasi dengan baik.

Model: "functional"

Layer (type)	Output Shape	Param #
input_layer_2 (InputLayer)	(None, 299, 299, 3)	0
true_divide (TrueDivide)	(None, 299, 299, 3)	0
subtract (Subtract)	(None, 299, 299, 3)	0
xception (Functional)	(None, 10, 10, 2048)	20,861,480
global_average_pooling2d (GlobalAveragePooling2D)	(None, 2048)	0
dropout (Dropout)	(None, 2048)	0
dense (Dense)	(None, 7)	14,343

Total params: 20,875,823 (79.63 MB)
 Trainable params: 14,343 (56.03 KB)
 Non-trainable params: 20,861,480 (79.58 MB)

Gambar 6 Arsitektur Model CNN berbasis XceptionNet

- c. Training dilakukan selama 35 epochs untuk mengenali pola dalam gambar dan mengklasifikasikan penyakit tanaman daun terong secara optimal.

70/70	10s 148ms/step	- accuracy: 0.9156 - loss: 0.2433 - val_accuracy: 0.8536 - val_loss: 0.6304
Epoch 21/35		
70/70	10s 150ms/step	- accuracy: 0.9019 - loss: 0.2829 - val_accuracy: 0.8393 - val_loss: 0.6400
Epoch 22/35		
70/70	11s 153ms/step	- accuracy: 0.9244 - loss: 0.2118 - val_accuracy: 0.8429 - val_loss: 0.6416
Epoch 23/35		
70/70	11s 160ms/step	- accuracy: 0.9129 - loss: 0.2745 - val_accuracy: 0.7929 - val_loss: 0.6752
Epoch 24/35		
70/70	12s 167ms/step	- accuracy: 0.9042 - loss: 0.2967 - val_accuracy: 0.8179 - val_loss: 0.6344
Epoch 25/35		
70/70	12s 168ms/step	- accuracy: 0.9086 - loss: 0.2866 - val_accuracy: 0.8321 - val_loss: 0.6571
Epoch 26/35		
70/70	11s 162ms/step	- accuracy: 0.9393 - loss: 0.1934 - val_accuracy: 0.8250 - val_loss: 0.6918
Epoch 27/35		
70/70	11s 156ms/step	- accuracy: 0.9204 - loss: 0.2557 - val_accuracy: 0.8250 - val_loss: 0.6757
Epoch 28/35		
70/70	11s 153ms/step	- accuracy: 0.9025 - loss: 0.2590 - val_accuracy: 0.8143 - val_loss: 0.8026
Epoch 29/35		
70/70	11s 153ms/step	- accuracy: 0.9234 - loss: 0.2229 - val_accuracy: 0.8179 - val_loss: 0.8329
Epoch 30/35		
70/70	11s 157ms/step	- accuracy: 0.9041 - loss: 0.2688 - val_accuracy: 0.7857 - val_loss: 0.9071
Epoch 31/35		
70/70	11s 161ms/step	- accuracy: 0.9197 - loss: 0.2559 - val_accuracy: 0.8321 - val_loss: 0.7260
Epoch 32/35		
70/70	11s 162ms/step	- accuracy: 0.9135 - loss: 0.2506 - val_accuracy: 0.8429 - val_loss: 0.7233
Epoch 33/35		
70/70	11s 161ms/step	- accuracy: 0.9221 - loss: 0.2254 - val_accuracy: 0.8321 - val_loss: 0.7151
Epoch 34/35		
70/70	11s 159ms/step	- accuracy: 0.9365 - loss: 0.1973 - val_accuracy: 0.8143 - val_loss: 0.8118
Epoch 35/35		
70/70	11s 158ms/step	- accuracy: 0.9109 - loss: 0.2561 - val_accuracy: 0.8214 - val_loss: 0.6749

Gambar 7 Proses Training

- d. Evaluasi model dilakukan dengan data testing untuk mengukur akurasi model dalam mengklasifikasi penyakit tanaman daun terong setelah pelatihan.

- e. Hasil klasifikasi, dari output akhir model CNN dengan arsitektur *XceptionNet* setelah melalui seluruh tahapan.

Pada penelitian ini dilakukan beberapa skenario pengujian untuk mengetahui parameter pelatihan model yang paling optimal. Pengujian dilakukan dengan mengubah beberapa parameter seperti *optimizer*, *learning rate*, dan jumlah *epoch*. Setiap skenario menghasilkan performa model yang berbeda sehingga diperlukan analisis untuk menentukan konfigurasi terbaik.

Tabel 1 Perbandingan Skenario Hasil Pelatihan Model

Skenario	Optimizer	Learning Rate	Epoch	Akurasi	Kondisi Grafik	Analisis / Proses Kerja
Pengujian 1	Adam	0.01	35	83,57%	<i>Stable</i>	Kondisi paling ideal (<i>Good Fit</i>) setelah <i>tuning</i> .
Pengujian 2	RMSprop	0.01	35	82%	<i>Overfitting</i>	<i>Gap training & validasi</i> sangat jauh; model menghafal data.
Pengujian 3	Adam & RMSprop	0.001	35	77%	<i>Underfitting</i>	Kenaikan mulai terlihat namun belum optimal.
Pengujian 4	Adam	0.0001	35	71%	<i>Underfitting</i>	Akurasi rendah karena langkah belajar terlalu kecil
Pengujian 5	RMSprop	0.0001	35	73%	<i>Underfitting</i>	Model lambat dalam mengenali fitur penyakit.
Pengujian 6	SGD	0.001	35	73%	<i>Fluktuasi</i>	Grafik berantakan (naik-turun) dan tidak stabil
Pengujian 7	Adam	0.0001	50	81%	<i>Fluktuasi</i>	Grafik zig-zag/berantakan selama proses <i>epoch</i>

Berdasarkan tabel 1, terlihat bahwa perubahan parameter pelatihan memberikan pengaruh terhadap kinerja model. Pengujian pertama menggunakan *optimizer Adam* dengan *learning rate* 0.01 dan *epoch* 35 menghasilkan akurasi tertinggi sebesar 83,57% dengan kondisi grafik yang stabil. Hal ini menunjukkan bahwa konfigurasi parameter tersebut mampu memberikan proses pembelajaran model yang paling optimal.

Optimizer Adam menunjukkan performa yang lebih stabil dibandingkan RMSprop karena mampu menyesuaikan *learning rate* secara adaptif pada setiap parameter. Hal ini menyebabkan proses konvergensi menjadi lebih cepat dan stabil.


RMSprop cenderung mengalami *overfitting* karena terlalu cepat menyesuaikan bobot terhadap data training, sehingga model kehilangan kemampuan generalisasi terhadap data baru.

Pada pengujian kedua menggunakan RMSprop, model mengalami kondisi *overfitting*, yang terlihat dari perbedaan yang cukup besar antara akurasi pelatihan dan validasi. Sementara pada beberapa pengujian lainnya ditemukan kondisi *underfitting*, yang menunjukkan bahwa model belum mampu mempelajari pola data secara optimal. Selain itu, terdapat juga kondisi *fluktuasi* grafik, yang menandakan proses pelatihan model kurang stabil selama proses *epoch*.

3.2 Analisis Proses Pelatihan Model

Hasil pelatihan model juga dianalisis menggunakan grafik akurasi dan *loss* selama proses *training*. Grafik ini digunakan untuk melihat bagaimana proses pembelajaran model dalam mengenali pola pada data citra daun terong.

Berdasarkan gambar 4 terlihat bahwa model mengalami peningkatan akurasi pada awal proses pelatihan, kemudian cenderung stabil setelah beberapa *epoch*. Hal ini menunjukkan bahwa model mulai mampu mempelajari fitur visual dari citra daun terong. Pada beberapa skenario terlihat *fluktuasi* grafik yang menunjukkan bahwa model masih mengalami kesulitan dalam mencapai konvergensi yang stabil.




Gambar 4 Grafik Training dan Validation

3.3 Evaluasi Kinerja Model

Setelah proses pelatihan selesai, model kemudian diuji menggunakan *Confusion Matrix* untuk melihat kemampuan model dalam mengklasifikasikan setiap kelas penyakit daun terong. Berdasarkan hasil *Confusion Matrix*, Sebagian besar data uji berhasil diklasifikasikan dengan benar oleh model. Hal ini menunjukkan bahwa model CNN dengan arsitektur *XceptionNet* mampu mengenali pola penyakit pada daun terong dengan cukup baik.

Berdasarkan confusion matrix, kesalahan klasifikasi sering terjadi antara kelas White Mold Disease dan Healthy Leaf. Hal ini disebabkan karena bercak putih pada penyakit White Mold memiliki karakteristik visual yang mirip dengan pantulan cahaya atau bagian terang pada daun sehat. Secara teknis, model CNN mengandalkan pola tekstur dan intensitas piksel, sehingga kemiripan ini menyebabkan model sulit membedakan kedua kelas tersebut secara akurat.

Namun masih terdapat beberapa kesalahan klasifikasi pada kelas yang memiliki kemiripan pola visual. Kesalahan ini umumnya terjadi karena beberapa jenis penyakit memiliki karakteristik bercak yang hampir sama sehingga model mengalami kesulitan dalam membedakan antar kelas tersebut.



Gambar 5 Confusion Matrix

Secara keseluruhan, hasil penelitian menunjukkan bahwa model CNN dengan arsitektur *XceptionNet* mampu melakukan klasifikasi penyakit daun terong dengan akurasi yang cukup baik,

yaitu 83,57%, sehingga berpotensi digunakan sebagai dasar pengembangan sistem identifikasi penyakit tanaman berbasis citra.

3.4 Classification Report

	precision	recall	f1-score	support
Healthy Leaf	0.80	0.89	0.84	36
Insect Pest Disease	0.80	0.76	0.78	37
Leaf Spot Disease	0.79	0.84	0.82	37
Mosaic Virus Disease	0.77	0.93	0.84	43
Small Leaf Disease	0.85	0.80	0.82	35
White Mold Disease	0.90	0.72	0.80	50
Wilt Disease	0.95	0.93	0.94	42
accuracy			0.84	280
macro avg	0.84	0.84	0.83	280
weighted avg	0.84	0.84	0.83	280

Gambar 6 Classification Report

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa model Convolutional Neural Network (CNN) dengan arsitektur XceptionNet mampu digunakan untuk melakukan klasifikasi penyakit daun terong berdasarkan citra. Hasil pengujian menunjukkan bahwa model mampu mencapai tingkat akurasi sebesar 83,57% pada data pengujian. Hasil ini menunjukkan bahwa arsitektur XceptionNet memiliki kemampuan yang cukup baik dalam mengekstraksi fitur visual dari citra daun terong sehingga dapat membedakan beberapa jenis penyakit pada tanaman terong. Dengan performa yang diperoleh, model ini berpotensi untuk dikembangkan lebih lanjut sebagai sistem identifikasi penyakit tanaman berbasis citra yang dapat membantu proses deteksi penyakit secara lebih cepat dan efisien.

5. SARAN

Berdasarkan hasil penelitian yang telah dilakukan, beberapa saran untuk pengembangan penelitian selanjutnya adalah sebagai berikut:

- Jumlah dataset dapat diperbanyak agar model memiliki variasi data yang lebih luas sehingga dapat meningkatkan performa klasifikasi.
- Penelitian selanjutnya dapat melakukan perbandingan dengan arsitektur CNN lainnya seperti ResNet, MobileNet, atau EfficientNet untuk mengetahui model yang memiliki performa terbaik dalam klasifikasi penyakit daun terong.
- Model yang telah dikembangkan dapat diimplementasikan dalam bentuk aplikasi berbasis mobile atau web sehingga dapat digunakan secara langsung oleh petani dalam melakukan identifikasi penyakit tanaman.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Bapak Muh. Syahlan Natsir, S.Kom., M.T. selaku Pembimbing I dan Bapak Muhammad Rusdi Rahman, S.Kom., M.Kom. selaku Pembimbing II atas bimbingan dan arahan selama proses penyusunan jurnal ini. Penulis juga menyampaikan terima kasih kepada Universitas DIPA Makassar atas dukungan akademik hingga jurnal ini dapat terselesaikan dengan baik.

DAFTAR PUSTAKA

- [1] T. Alighadri, M. Tabibiazar, M. Mohammadi, A. Jahanban-Esfahlan, and R. Amarowicz, "Nasunin, an amazing chemical constituent in eggplants (*Solanum melongena* L.): A review of its major properties and health-promoting effects," *ACS Food Science & Technology*, vol. 4, no. 1, pp. 16–35, 2024, doi: 10.1021/acsfoodscitech.3c00582.
- [2] K. R. Aravind, P. Raja, R. Ashiwin, and K. V. Mukesh, "Disease classification in *Solanum melongena* using deep learning," *Spanish Journal of Agricultural Research*, vol. 17, no. 3, Art. no. e0204, 2019, doi: 10.5424/sjar/2019173-14762.
- [3] P. S. Thakur, P. Khanna, T. Sheorey, and A. Ojha, "Trends in vision-based machine learning techniques for plant disease identification: A systematic review," *Expert Systems with Applications*, vol. 208, Art. no. 118117, 2022, doi: 10.1016/j.eswa.2022.118117.
- [4] M. Shoaib, B. Shah, S. Ei-Sappagh, A. Ali, A. Ullah, F. Alenezi, T. Gechev, T. Hussain, and F. Ali, "An advanced deep learning models-based plant disease detection: A review of recent research," *Frontiers in Plant Science*, vol. 14, Art. no. 1158933, 2023, doi: 10.3389/fpls.2023.1158933.
- [5] C. Sarkar, D. Gupta, U. Gupta, and B. B. Hazarika, "Leaf disease detection using machine learning and deep learning: Review and challenges," *Applied Soft Computing*, vol. 145, Art. no. 110534, 2023, doi: 10.1016/j.asoc.2023.110534.
- [6] H. Noprisson, "Fine-tuning model transfer learning VGG16 untuk klasifikasi citra penyakit tanaman padi," *JSAI (Journal Scientific and Applied Informatics)*, vol. 5, no. 3, pp. 244–249, 2022, doi: 10.36085/jsai.v5i3.3609.
- [7] W. I. A. E. Altabaji, M. Umair, W.-H. Tan, Y.-L. Foo, and C.-P. Ooi, "Comparative analysis of transfer learning, LeafNet, and Modified LeafNet models for accurate rice leaf diseases classification," *IEEE Access*, vol. 12, pp. 36622–36635, 2024, doi: 10.1109/ACCESS.2024.3373000.
- [8] A. R. Muslikh, D. R. I. M. Setiadi, and A. A. Ojugo, "Rice disease recognition using transfer learning Xception convolutional neural network," *Jurnal Teknik Informatika (JUTIF)*, vol. 4, no. 6, pp. 1541–1547, 2023, doi: 10.52436/1.jutif.2023.4.6.1529.
- [9] A. Abisha and N. Bharathi, "A hybrid feature extraction and classification using Xception-RF for multiclass disease classification in plant leaves," *Applied Artificial Intelligence*, vol. 37, no. 1, Art. no. 2176614, 2023, doi: 10.1080/08839514.2023.2176614.
- [10] F. Chollet, "Xception: Deep learning with depthwise separable convolutions," in *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 1251–1258, doi: 10.1109/CVPR.2017.195.
- [11] K. C. Kamal, Z. Yin, M. Wu, and Z. Wu, "Depthwise separable convolution architectures for plant disease classification," *Computers and Electronics in Agriculture*, vol. 165, Art. no. 104948, 2019, doi: 10.1016/j.compag.2019.104948.
- [12] Suryani and M. S. Natsir, "Optimizing a fire and smoke detection system model with hyperparameter tuning and callback on forest fire images using ConvNet algorithm," *ILKOM Jurnal Ilmiah*, vol. 16, no. 1, pp. 46–58, 2024, doi: 10.33096/ilkom.v16i1.1937.46-58.