

# Klasifikasi Algoritma Jaringan Syaraf Tiruan Konvolusi untuk Deteksi Hama pada Kangkung

## *Classification using Convolutional Neural Network Algorithms for Pest Detection in Water Spinach*

<sup>1</sup>Riki Hikmianto\*, <sup>2</sup>Ema Utami

<sup>1,2</sup>Informatika Program Magister, Universitas Amikom Yogyakarta

<sup>1,2</sup>Jl. Ring Road Utara, Ngringin, Condongcatur, Kec. Depok, Kabupaten Sleman, Daerah Istimewa  
Yogyakarta 55281

\*e-mail: [rikihikmianto@students.amikom.ac.id](mailto:rikihikmianto@students.amikom.ac.id)

(received: 4 January 2025, revised: 6 January 2025, accepted: 9 January 2025)

### Abstrak

Penelitian ini mengkaji penerapan algoritma jaringan syaraf tiruan *konvolusi* (*Convolutional Neural Network, CNN*) dalam mendeteksi hama pada tanaman kangkung menggunakan dua arsitektur CNN, yaitu *MobileNetV2* dan *VGG16*. Masalah utama mengawasi daun yang sakit selama fase pertumbuhan tanaman adalah langkah penting. Oleh karena itu, solusi berbasis kecerdasan buatan diperlukan untuk meningkatkan akurasi deteksi hama secara otomatis. Dalam penelitian ini, dataset gambar daun kangkung yang terinfeksi hama dan yang sehat dikumpulkan untuk melatih kedua arsitektur CNN tersebut. *MobileNetV2* dipilih karena kemampuannya dalam memberikan performa tinggi dengan kompleksitas komputasi rendah, sementara *VGG16* digunakan sebagai pembanding karena arsitekturnya yang lebih dalam dan sering digunakan dalam berbagai tugas pengenalan gambar. Hasil pengujian menunjukkan bahwa *MobileNetV2* mencapai akurasi deteksi sebesar 84%, sedangkan *VGG16* menghasilkan akurasi sebesar 83%. Dengan demikian, *MobileNetV2* dinilai lebih unggul untuk aplikasi deteksi hama ini karena mampu memberikan keseimbangan antara akurasi yang tinggi dan efisiensi komputasi yang optimal. Studi ini menyimpulkan bahwa *MobileNetV2* merupakan pilihan arsitektur yang lebih tepat untuk sistem deteksi hama pada tanaman kangkung, khususnya dalam aplikasi yang memerlukan performa tinggi pada perangkat dengan sumber daya terbatas.

**Kata kunci:** CNN, VGG16, mobilenetv2, deep learning, daun

### Abstract

*This study examines the application of Convolutional Neural Network (CNN) algorithms in detecting pests on water spinach plants using two CNN architectures: MobileNetV2 and VGG16. Monitoring diseased leaves during the plant growth phase is a critical step, and AI-based solutions are essential to enhance the accuracy of automated pest detection. In this research, a dataset of water spinach leaf images, both pest-infected and healthy, was collected to train the two CNN architectures. MobileNetV2 was selected for its ability to deliver high performance with low computational complexity, while VGG16 was used as a benchmark due to its deeper architecture and widespread use in various image recognition tasks. The testing results indicate that MobileNetV2 achieved a detection accuracy of 84%, while VGG16 yielded an accuracy of 83%. Thus, MobileNetV2 is considered superior for this pest detection application as it provides a balance between high accuracy and optimal computational efficiency. The study concludes that MobileNetV2 is a more suitable architecture for pest detection systems in water spinach plants, particularly for applications requiring high performance on resource-constrained devices.*

**Keywords:** CNN, VGG16, mobileNetV2, deep learning, leaves

## 1 Pendahuluan

Baru-baru ini, penerapan kecerdasan buatan dalam sektor pertanian telah menjadi sangat krusial. Inovasi teknologi dalam pertanian dapat dilakukan dengan cara-cara kreatif. Mengawasi daun yang sakit selama fase pertumbuhan tanaman adalah langkah penting. Deteksi dini penyakit, klasifikasi,

<http://sistemasi.ftik.unisi.ac.id>

dan analisis daun yang terinfeksi, serta solusi potensialnya, sangat mendukung kemajuan pertanian [1]. Penelitian ini berfokus terutama pada deteksi dan klasifikasi penyakit pada berbagai tanaman, khususnya pada daun kangkung yang merupakan sayuran yang cukup populer bagi masyarakat Indonesia [2].

Bentuk daun adalah kunci untuk identifikasi dan klasifikasi tanaman serta penyakitnya. Teknik ini sangat berguna untuk studi pertanian, konservasi, dan ekologi [3]. Daun tanaman sendiri memiliki variasi morfologi yang menyediakan data kaya untuk studi klasifikasi. Memahami pertumbuhan dan klasifikasi daun dapat meningkatkan praktik budidaya dan hasil panen [4].

Beberapa jurnal sudah membahas tentang teknik klasifikasi penyakit tanaman yang sangat populer seperti *Convolutional Neural Network (CNN)* [5], *K-Nearest Neighbors (KNN)* dengan *Gray-Level Co-occurrence Matrix (GLCM)* [6], *Support Vector Machine (SVM)* [7], *ResNet (Residual Network)* [8] dan *NCAM (Neural Cellular Automaton Machine)* dengan dikombinasikan dengan *MobileNetXt* [9].

Untuk teknik KNN sendiri merupakan algoritma yang sederhana dan mudah diimplementasikan, tetapi menghitung jarak ke semua titik data dalam set pelatihan bisa sangat mahal [10]. Walaupun CNN telah terbukti menjadi pendekatan yang paling sukses dan banyak digunakan untuk mengidentifikasi penyakit pada tanaman yang sudah dilatih. Namun, metode ini memakan waktu karena kelangkaan set data yang benar-benar besar dan signifikan [7]. Sedangkan untuk arsitektur ResNet memiliki banyak parameter yang dapat dilatih, yang meningkatkan kemampuan untuk mempelajari pola dan karakteristik data yang kompleks tetapi ResNet dengan pengoptimalan tertentu mengindikasikan adanya potensi kelemahan dalam kinerja [11].

Sementara *MobileNetXt* merupakan model jaringan neural yang ringan khusus untuk tugas klasifikasi dengan struktur yang dioptimalkan ditambah dengan NCAM yang membantu meningkatkan kemampuan model dalam mengekstraksi fitur yang relevan dari gambar, akan tetapi sumber daya komputasi yang lebih besar dengan peningkatan waktu pelatihan dan penggunaan sumber daya komputasi yang lebih tinggi membuat model ini cenderung *overfitting* pada data latih tertentu [9].

Penggunaan metode *MobileNetXt* dengan NCAM telah diterapkan untuk klasifikasi jenis daun tanaman [9]. Sedangkan metode CNN dengan arsitektur *Visual Graphics Group 16 (VGG-16)* juga telah digunakan untuk tujuan yang sama [12]. Perbandingan antara SVM, Random Forest dan CNN dengan arsitektur *ResNet50* dan *VGG-16* [13] dan *Artificial Neural Network (ANN)* [14] untuk klasifikasi daun tanaman menunjukkan bahwa CNN dapat menjadi alternatif yang efektif dengan akurasi tinggi. Tetapi CNN memiliki kelemahan yaitu proses pelatihan yang cukup lama [12].

Arsitektur *MobileNetV2* terkenal karena efisiensi komputasinya yang tinggi, terutama pada perangkat bergerak. *MobileNetV2* lebih efisien dan berkinerja lebih baik dibandingkan CNN konvensional [15]. Dalam penelitian ini, akan dibandingkan arsitektur *MobileNetV2* dan VGG-16 pada model CNN untuk mengetahui mana yang lebih efisien. Pengujian ini juga akan mengevaluasi model dalam klasifikasi citra daun, dengan tujuan memahami trade-off antara efisiensi dan akurasi. Hasil perbandingan ini diharapkan memberikan wawasan tentang penggunaan optimal *MobileNetV2* dan VGG-16 dalam pengolahan citra menggunakan *Convolutional Neural Network (CNN)*.

## 2 Tinjauan Literatur

Para Peneliti sebelumnya telah melakukan penelitian mengenai klasifikasi khususnya dalam bidang pertanian termasuk dalam daun kangkung, maka dari itu berikut tinjauan Pustaka yang diambil dalam lima tahun terakhir :

Klasifikasi otomatis yang diusulkan pada penelitian Y. Xu [9] untuk mengatasi stress air yang tidak efisien pada bibit kangkung. penelitian ini secara inovatif mengusulkan *Normalization-based Channel Attention Module (NCAM)* untuk meningkatkan fitur gambar secara jelas. Hasil dari penelitian ini menunjukkan bahwa akurasi klasifikasi model *N-MobileNetXt* untuk bibit kangkung mencapai 90,35%. Dataset yang digunakan pada penelitian ini terdiri dari 2000 gambar tanpa adanya augmentasi. Penelitian ini menekankan automasi langsung, sehingga kecerahan maupun kondisi sekitar tanaman tidak diperhatikan. Akibatnya, penerapan pada beberapa metode lainnya kurang optimal.

Makalah ini menyajikan CNN dengan berbagai arsitektur yang digunakan mulai dari *Visual Geometry Group 16 (VGG16)*, *Visual Geometry Group 19 (VGG19)* dan *Residual Network 50 (ResNet50)* [13]. Makalah ini juga membandingkan antara CNN, SVM, dan Random Forest akan tetapi yang paling diunggulkan dari adalah CNN dengan 97,5% sedangkan SVM 83%, Random Forest 85%, VGG16 93%, VGG19 94,5%, ResNet50 95%. Namun Dataset yang digunakan pada penelitian ini terbatas dengan menggunakan 400 gambar dengan 100 gambar pada setiap satu kelasnya.

Pada penelitian yang dilakukan oleh M. Islam [12], data yang digunakan terdiri dari 5 spesies daun bayam dengan 3785 gambar. Empat model CNN digunakan untuk klasifikasi daun, yaitu InceptionV2 dengan akurasi 98,68%, Xception dengan akurasi 98,73%, VGG19 dengan akurasi 99,26%, dan VGG16 dengan akurasi 99,79%. Di antara model-model tersebut, VGG16 mencapai akurasi tertinggi pada penelitian ini. Meskipun penelitian ini mencapai akurasi tinggi, penelitian ini tidak menjelaskan secara eksplisit pengujian maupun struktur atau layer dari arsitektur yang digunakan.

Model CNN dan model yang telah dilatih sebelumnya seperti model VGG, ResNet, dan DenseNet untuk mengklasifikasikan penyakit tanaman yang berbeda dan mengidentifikasi berbagai penyakit menggunakan kamera ponsel [5]. Dari hasil matrik evaluasi kinerja yang diberikan kurasi, presisi, recall, dan skor F1 menunjukkan bahwa Model DenseNet mencapai akurasi tertinggi sebesar 98,27%. Model DenseNet yang digunakan memiliki performa tinggi namun mungkin kurang efisien dalam hal kecepatan dan penggunaan sumber daya komputasi. Penelitian selanjutnya akan berfokus pada optimasi model menggunakan MobileNetV2 untuk digunakan pada perangkat dengan sumber daya terbatas, seperti smartphone, tanpa mengorbankan akurasi.

Pada penelitian D. Sugiarto [16], sebuah aplikasi mobile dikembangkan untuk mengenali tanaman obat dari citra daun berdasarkan pada CNN. Model yang digunakan CNN, VGG-16, MobileNetV2, dan DenseNet-121, diselidiki sebagai dasar untuk mengklasifikasikan 24 tanaman obat dengan memodifikasi lapisan yang terhubung sepenuhnya. Hasil percobaan pada 24 jenis tanaman obat menunjukkan bahwa model berbasis MobileNetV2 mencapai yang terbaik akurasi klasifikasi terbaik sebesar 97,74%. Model dengan akurasi klasifikasi tertinggi tersebut kemudian diimplementasikan dalam sebuah aplikasi mobile untuk pengenalan tanaman obat. Meskipun dataset yang digunakan dalam penelitian ini mencakup berbagai tanaman obat, dataset ini mungkin tidak mencakup keragaman bentuk, ukuran, dan kondisi daun (misalnya, daun yang sakit vs daun yang sehat). Pada penelitian selanjutnya akan berfokus pada pengklasifikasian pada kondisi daun yang sehat maupun yang tidak sehat.

Pada penelitian yang dilakukan oleh S. Vallabhajosyula [11] transfer learning digunakan seperti ResNet 50 & 101, InceptionV2, DenseNet 121 & 201, MobileNetV2, dan NasNet. model yang diusulkan dievaluasi pada dataset desa tanaman yang tersedia untuk umum, yang terdiri dari 38 kelas yang dikumpulkan dari 14 tanaman. Model yang paling tinggi akurasinya ditunjukkan oleh model ResNet yang mencapai 99%. Pada penelitian selanjutnya bisa menambahkan model seperti VGG16 dan MobileNetV2 ini untuk meningkatkan akurasi dan efisiensi komputasi.

Penerapan VGG-16 dilakukan pada penelitian S. U. Habiba [17] untuk mengklasifikasikan penyakit tanaman tomat. Tidak hanya dengan VGG-16 tapi penelitian ini juga mencoba dengan arsitektur CNN dan SVM untuk mengklasifikasi akan tetapi hasil dari VGG-16 95,5% yang menunjukkan bahwa VGG-16 unggul dalam segi mengklasifikasi. Untuk datasenya sendiri penelitian ini menggunakan Plant Village dataset yang berisi sepuluh kelas gambar daun tomat termasuk tanaman sehat akan tetapi tidak disebutkan berapa jumlah total gambar yang digunakan dalam dataset ini.

Sebuah jaringan syaraf konvolusional bertingkat atau Multilayer Convolutional Neural Network (MCNN) diterapkan untuk klasifikasi gambar daun tanaman yang sakit dengan 4 jenis daun tanaman sebanyak 1345 gambar [18]. Untuk hasilnya sendiri metode yang diusulkan memang paling tinggi yakni 98,24% akan tetapi waktu yang dibutuhkan pada penelitian ini 2 setengah hari, adapun model yang mendekati Radial Basis Function Neural Network (RBFNN) 95.21%. sehingga untuk penelitian ini dapat ditingkatkan dengan mempertimbangkan model transfer learning seperti VGG, MobileNet, ResNet dan yang lainnya.

Penelitian L. Rodrigues [19] menggunakan dataset yang terdiri dari 4123 gambar, yang dikumpulkan secara manual selama berbagai musim tanam dari delapan jenis tanaman sayuran. Model yang digunakan ada beberapa seperti YOLOV4, SSD InceptionV2, SSD MobileNetV2 dan SSD

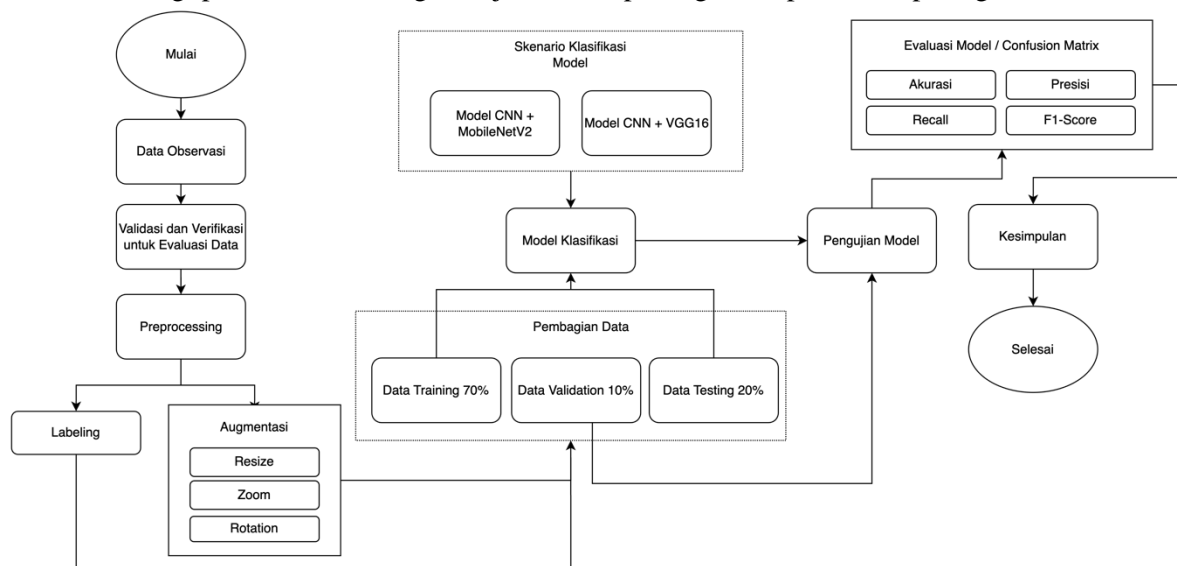
<http://sistemasi.ftik.unisi.ac.id>

ResNet50 akan tetapi Model YOLO v4 terbukti sebagai model terbaik dalam penelitian ini, mencapai mAP (mean Average Precision) sebesar 76.6% dan akurasi klasifikasi (BA) sebesar 81.7%. Hasil ini menunjukkan bahwa model YOLOV4 efektif dalam mengklasifikasikan fase fenologi dari kemunculan hingga panen.

Penelitian A. Sinha [20] mengembangkan teknik klasifikasi baru untuk mendeteksi penyakit hawar dan bercak pada daun tanaman dataset Plant Village menggunakan fitur tekstur dari GLCM. Metode ini melibatkan langkah segmentasi ROI dengan K-means segmentation, Delta-E color segmentation, dan color space histogram thresholding. Fitur tekstur kemudian diekstraksi dari GLCM dalam empat arah (0°, 45°, 90°, dan 135°) dan dioptimalkan untuk membentuk set fitur yang sangat berkorelasi. Hasilnya, teknik ini mencapai akurasi 74% dalam skenario terbaik dengan nilai ambang optimal 1250, menunjukkan efektivitas dalam mengidentifikasi penyakit tanaman pada gambar dengan pola infeksi yang menonjol.

### 3 Metode Penelitian

Metodologi penelitian ini dibagi menjadi beberapa langkah dapat dilihat pada gambar **Gambar 1**



**Gambar 1.** Alur metode penelitian

Penjelasan pada **Gambar 1** pertama pengumpulan dataset daun kangkung yang dilakukan dengan observasi kemudian dataset yang bukan daun kangkung dihapus. Setelah itu melakukan pemrosesan gambar seperti split data dan mengatur size gambar yang ada setelahnya melakukan pelatihan dan pengujian untuk arsitektur MobileNetV2 dan VGG16. Setelah pelatihan dan pengujian kemudian dilakukan analisis untuk masing masing arsitektur yang sudah digunakan seperti kecepatan komputasi epoch yang digunakan, accuracy, presisi, f1-score dan confusion matrix.

#### A. Pengambilan Data

Pengumpulan data dalam penelitian ini dilakukan menggunakan dataset yang diperoleh dari observasi sawah yang ada pada Nusa Tenggara Barat. Selanjutnya, dilakukan pengecekan untuk memvalidasi hanya data daun yang akan digunakan, sementara data-data seperti batang dan hewan/hama tidak dimasukkan dalam analisis. Pendekatan ini memastikan bahwa fokus penelitian terpusat pada karakteristik dan atribut yang terkait langsung dengan citra daun kangkung, meningkatkan validitas dan relevansi hasil penelitian terhadap tujuan spesifik yang ingin dicapai. Untuk gambar yang digunakan sebanyak 1600 gambar untuk 4 kelas, contoh pada **Gambar 2**



**Gambar 2. Penyakit citra daun kangkung**

## **B. Pemrosesan Gambar**

Pada tahap pre-processing data, gambar diubah pada dataset yang dikumpulkan. Tujuan dari proses ini adalah untuk mengurangi ukuran gambar, yang diharapkan akan mengurangi waktu komputasi selama proses pelatihan model CNN. Ukuran gambar diubah menjadi 128 x 128 piksel dari ukuran piksel sebelumnya yang masih acak akan di sama rataakan. Jumlah gambar yang tersedia pada dataset ini hanya 1600 gambar, yang dapat berdampak pada akurasi model CNN selama pelatihan karena dataset ini memiliki banyak kelas dengan masing-masing 400 gambar.

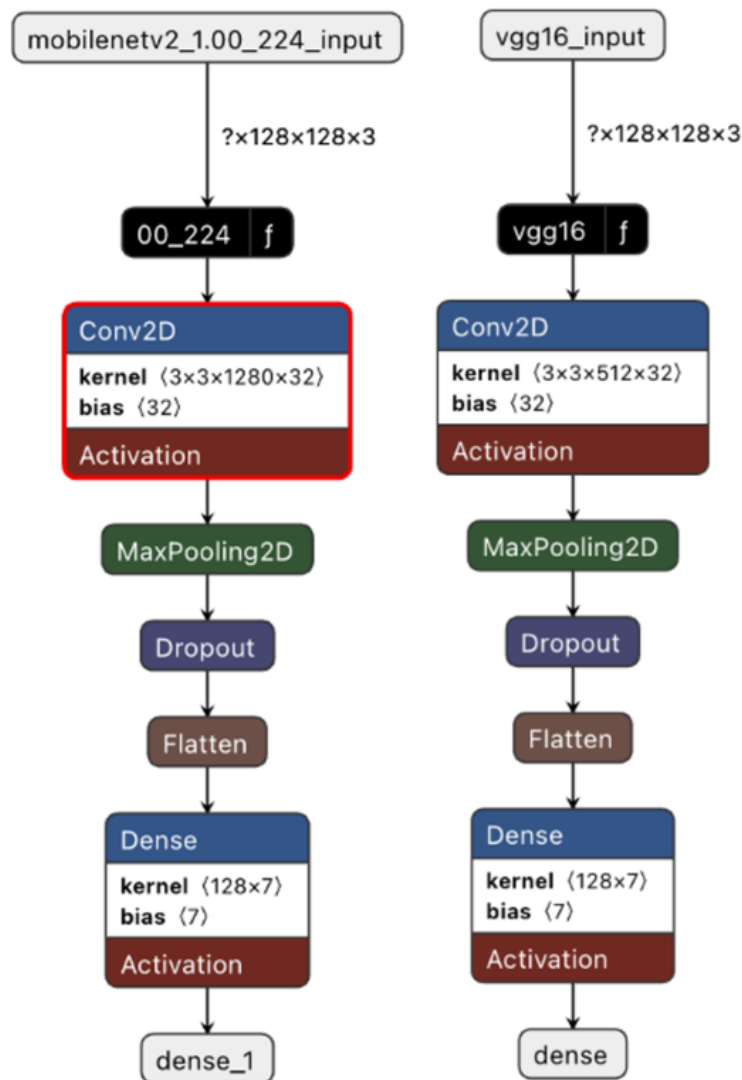
## **C. Arsitektur**

MobileNetV2 adalah arsitektur jaringan syaraf convolutional yang dimaksudkan untuk berfungsi dengan baik pada perangkat seluler. Struktur residual terbalik, di mana koneksi residual berada di antara lapisan kemacetan, adalah basisnya. Lapisan ekspansi menengah menggunakan konvolusi kedalaman yang ringan untuk menyaring fitur sebagai sumber non-linearitas. Lapisan konvolusi penuh awal dengan 32 filter diikuti oleh 19 lapisan bottleneck residual dalam arsitektur MobileNetV2 [21].

Seperti namanya, VGG16 adalah jaringan syaraf dengan kedalaman 16 lapisan, sehingga relatif luas dengan 138 juta parameter, yang sangat besar bahkan menurut standar saat ini. Namun, daya tarik utama dari arsitektur VGGNet16 adalah kesederhanaannya. Arsitektur VGGNet menggabungkan fitur yang paling penting dari jaringan syaraf tiruan konvolusi: jaringan VGG terdiri dari filter konvolusi kecil, dan VGGNet16 memiliki tiga lapisan yang terhubung penuh dan tiga belas lapisan konvolusi [22]

Untuk gambaran layer pada setiap arsitektur dapat lebih jelasnya dilihat pada Gambar 3





Gambar 3. Arsitektur mobilenetV2 dan VGG16

#### D. Evaluasi Model

Pada tahap ini bertujuan untuk mengevaluasi kinerja model CNN arsitektur MobileNetV2 dan VGG16. Evaluasi model akan dilakukan dengan menggunakan confusion matrix untuk mengetahui nilai accuracy, precision, recall dan f1-score, dan time komputasi yang ada dari model yang digunakan ditunjukkan pada Tabel 1

Tabel 1. Confusion matrix

		Production			
		Class 1	Class 2	...	Class n
Actual Class	Class 1	$x_{11}$	$x_{12}$	...	$x_{1n}$
	Class 2	$x_{21}$	$x_{22}$	...	$x_{2n}$
	...	...	...	...	...
	Class n	$x_{n1}$	$x_{n2}$	...	$x_{nn}$

Dari Tabel 1 di atas, kita akan menghitung jumlah total false negative (TFN), false positive (TFP), dan true negative (TTN) untuk setiap kelas  $i$  berdasarkan Persamaan Umum 1, 2, dan 3. Total true positive dalam sistem dapat dihitung melalui Persamaan 4 [23].

$$TPP_{all} = \sum_{j=1}^n x_{jj} \tag{1}$$

$$TTN_i = \sum_{j=1}^n \sum_{\substack{k=1 \\ k \neq i}}^n x_{jk} \quad (2)$$

$$TFP_i = \sum_{j=1}^n x_{ji} \quad (3)$$

$$TFN_i = \sum_{\substack{j=1 \\ j \neq i}}^n x_{ij} \quad (4)$$

Selanjutnya, akurasi (A), presisi (P), recall (R), dan spesifisitas (S) untuk setiap kelas  $i$  juga dihitung seperti yang ditunjukkan pada persamaan 5, 6, 7 dan 8. F1-Score dihitung sebagai ditunjukkan pada persamaan 9 [23].

$$Accuracy = \frac{TPP_{all}}{(Total\ Number\ of\ Entries)} \quad (5)$$

$$P_i = \frac{TPP_{all}}{TPP_{all} + TFP_i} \quad (6)$$

$$R_i = \frac{TPP_{all}}{TPP_{all} + TFN_i} \quad (7)$$

$$S_i = \frac{TTN_{all}}{TTN_{all} + TFP_i} \quad (8)$$

$$F1 - Score = \frac{TPP_{all}}{(Total\ Number\ of\ Entries)} \quad (9)$$

#### 4 Hasil dan Pembahasan

Hasil dari percobaan akan dijelaskan di bagian ini. Eksperimen ini dilakukan dengan melatih data pelatihan dan validasi menggunakan arsitektur MobileNetV2 dan VGG16. Pada tahap pelatihan model, setiap epoch yang digunakan dibandingkan untuk menganalisis model terbaik. Hasil pengujian dari masing-masing arsitektur diberikan di bawah ini.

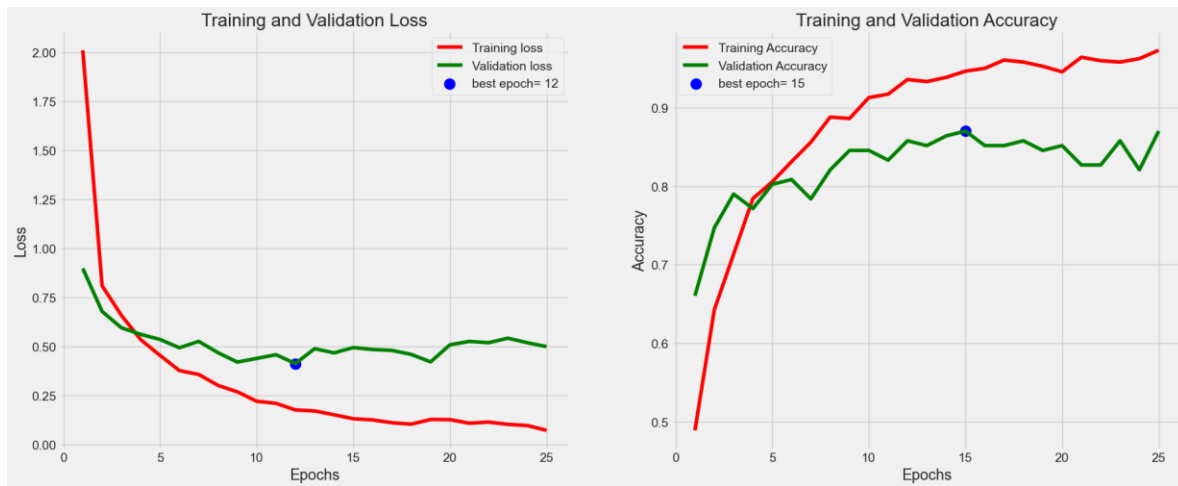
##### A. Arsitektur MobileNetV2

Pengujian dengan arsitektur MobileNetV2 dilakukan untuk mengetahui performa dan tingkat akurasi untuk pengolahan citra gambar pada daun kangkung.

**Tabel 2. Hasil arsitektur mobilenetv2**

Epoch	Time	Accuracy	Loss
10	124.44 seconds	82.13 %	71.22 %
25	258.67 seconds	84.01 %	59.64 %
50	347.48 seconds	81.82 %	85.14 %

**Tabel 2** menunjukkan bahwa MobileNetV2 pada epoch 25 memberikan hasil terbaik dengan akurasi 84% dan loss 59.64%. Ini menunjukkan bahwa MobileNetV2 memiliki kemampuan untuk mencapai akurasi tinggi dalam jumlah epoch yang moderat, yang konsisten dengan temuan dari penelitian [15], di mana MobileNetV2 juga menunjukkan performa optimal dengan jumlah epoch yang lebih sedikit dibandingkan arsitektur yang lebih dalam seperti VGG16. Namun, penelitian lain [9] menunjukkan bahwa penggunaan teknik augmentasi data lebih lanjut dapat meningkatkan akurasi MobileNetV2 hingga 90%.



**Gambar 4. Grafik akurasi dan loss mobilenetv2**

Grafik Gambar 4 menunjukkan bahwa Training Loss (merah) terus menurun dan tetap sangat rendah, menunjukkan performa model yang sangat baik pada data pelatihan. Sementara itu, Validation Loss (hijau) awalnya menurun, tetapi setelah beberapa epoch mulai meningkat atau stabil pada level yang lebih tinggi daripada training loss, mengindikasikan model mulai kehilangan kemampuan generalisasi pada data validasi meskipun terus membaik pada data pelatihan. Training Accuracy (merah) meningkat pesat hingga hampir 100%, menandakan model sangat akurat pada data pelatihan. Namun, Validation Accuracy (hijau), meskipun meningkat pada awalnya, tidak mencapai akurasi yang sama tinggi seperti data pelatihan dan mulai mendatar atau sedikit menurun, menunjukkan bahwa meskipun model sangat akurat pada data pelatihan, kinerjanya pada data validasi kurang baik.

## B. Arsitektur MobileNetV2


Pengujian dengan arsitektur VGG16 dilakukan untuk mengetahui performa dan tingkat akurasi untuk pengolahan citra gambar pada daun kangkung.

**Tabel 3. Hasil arsitektur vgg16**

Epoch	Time	Accuracy	Loss
10	1380.59 seconds	78.37 %	54.60 %
25	2777.86 seconds	82.76 %	46.96 %
50	3906.15 seconds	82.13 %	51.24 %

Tabel 3 secara jelas menunjukkan bahwa penggunaan epoch ke-25 menghasilkan akurasi yang optimal dengan loss yang rendah. Ini menandakan bahwa pada epoch 25, model mencapai keseimbangan yang baik antara pembelajaran dan generalisasi, dengan risiko **overfitting** dan **underfitting** yang minimal. Sementara epoch yang lebih besar (misalnya, 50 epoch) tidak memberikan peningkatan akurasi yang signifikan, bahkan justru berpotensi menyebabkan peningkatan loss yang menandakan adanya kemungkinan **overfitting**. Konsistensi antara akurasi data pelatihan dan validasi pada epoch 25 menunjukkan bahwa model mampu menggeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya, sebagaimana dijelaskan dalam studi [11] yang juga menekankan pentingnya memilih jumlah epoch yang tepat untuk mencegah **overfitting**.





**Gambar 5. Grafik akurasi dan loss mobilenetv2**

Grafik pada Gambar 5 tersebut menampilkan dua visualisasi performa model machine learning. Di sebelah kiri, grafik Training and Validation Loss menunjukkan Training Loss (merah) yang terus menurun secara signifikan dari nilai sekitar 1.4 hingga mendekati 0.2, mengindikasikan pembelajaran yang efektif pada data training. Sementara Validation Loss (hijau) awalnya menurun seiring dengan Training Loss, namun kemudian cenderung stabil di sekitar nilai 0.4, menunjukkan adanya gap dengan Training Loss yang mengindikasikan potensi overfitting. Di sebelah kanan, grafik Training and Validation Accuracy memperlihatkan Training Accuracy (merah) yang meningkat pesat dari 0.4 hingga mencapai hampir 0.9 atau 90% akurasi, menandakan model sangat baik dalam mempelajari pola data training. Namun, Validation Accuracy (hijau) meski meningkat di awal, hanya mencapai sekitar 0.8 atau 80% dan cenderung berfluktuasi di level tersebut, menguatkan indikasi bahwa model mengalami overfitting dimana performanya sangat baik pada data training tetapi kurang optimal dalam melakukan generalisasi pada data validasi yang belum pernah dilihat sebelumnya.


**C. Evaluasi Model**

Kedua arsitektur dengan epoch terbaik diuji untuk mendapatkan nilai akurasi, precision, recall, dan f1-score. Confusion matrix dari kedua arsitektur ini disajikan di sini untuk mengetahui perbandingan performa dari arsitektur yang digunakan.

		Confusion Matrix			
		bercak	kuning	lubang	sehat
Actual	bercak	60	1	11	4
	kuning	5	79	1	0
	lubang	17	0	60	8
	sehat	3	0	1	69
		bercak	kuning	lubang	sehat
		Predicted			

**Gambar 6. Confusion matrix mobilenetv2**

Confusion Matrix pada Gambar 6 ini menggambarkan performa model dalam mengklasifikasikan empat kategori: bercak, kuning, lubang, dan sehat. Pada kelas bercak, model berhasil memprediksi dengan benar 60 kasus (true positive), namun juga melakukan kesalahan dengan memprediksi 1 kasus sebagai kuning, 11 kasus sebagai lubang, dan 4 kasus sebagai sehat. Untuk kelas kuning, model mencapai akurasi tinggi dengan 79 prediksi benar, meskipun terdapat 5 kasus yang salah diklasifikasikan sebagai bercak dan 1 kasus sebagai lubang. Pada kategori lubang, model berhasil mengidentifikasi 60 kasus dengan tepat, tetapi terjadi kesalahan klasifikasi dimana 17 kasus diprediksi sebagai bercak dan 8 kasus sebagai sehat. Sementara untuk kelas sehat, model menunjukkan performa yang baik dengan 69 prediksi benar, meski terdapat beberapa kesalahan dimana 3 kasus diprediksi sebagai bercak dan 1 kasus sebagai lubang. Secara keseluruhan, diagonal utama matrix yang menunjukkan prediksi benar memiliki nilai yang relatif tinggi, mengindikasikan bahwa model memiliki performa yang cukup baik dalam mengklasifikasikan keempat kategori tersebut, meskipun masih terdapat beberapa kesalahan klasifikasi antar kelas.



**Gambar 7. Confusion matrix VGG16**

Confusion Matrix pada Gambar 7 ini memvisualisasikan hasil klasifikasi model untuk empat kategori: bercak, kuning, lubang, dan sehat. Pada kelas bercak, model berhasil memprediksi dengan tepat 51 kasus, namun terdapat kesalahan prediksi dimana ada 2 kasus diprediksi sebagai kuning, 11 kasus sebagai lubang, dan 12 kasus sebagai sehat. Untuk kelas kuning, model menunjukkan performa yang baik dengan 75 prediksi benar, meskipun ada 4 kasus yang salah diklasifikasikan sebagai bercak, 3 kasus sebagai lubang, dan 3 kasus sebagai sehat. Pada kategori lubang, model berhasil mengidentifikasi 72 kasus dengan tepat, tetapi terdapat kesalahan klasifikasi dimana 4 kasus diprediksi sebagai bercak dan 9 kasus sebagai sehat. Sementara untuk kelas sehat, model mencapai 66 prediksi yang benar, meski terjadi beberapa kesalahan dimana 5 kasus diprediksi sebagai bercak, 1 kasus sebagai kuning, dan 1 kasus sebagai lubang. Secara keseluruhan, nilai-nilai pada diagonal utama matrix yang menunjukkan prediksi benar cukup tinggi, mengindikasikan bahwa model memiliki performa yang cukup baik dalam mengklasifikasikan keempat kategori, meskipun masih ada ruang untuk peningkatan mengingat adanya kesalahan klasifikasi yang tersebar di berbagai kelas.

**Tabel 4. Hasil evaluasi model arsitektur**

Model	Akurasi	Precision	Recall	F1-Score
MobileNetV2	84 %	84 %	84 %	84 %
VGG16	83 %	83 %	83 %	82 %

Berdasarkan Tabel 4, arsitektur MobileNetV2 menunjukkan performa yang lebih unggul dibandingkan VGG16, dengan akurasi, precision, recall, dan f1-score yang konsisten berada di angka 84%. Hal ini menandakan bahwa MobileNetV2 tidak hanya mampu mengklasifikasikan data dengan akurasi yang baik, tetapi juga mempertahankan keseimbangan antara precision dan recall, yang penting untuk mengurangi kesalahan dalam prediksi positif dan negatif. Sementara itu, VGG16 sedikit tertinggal dengan akurasi 83%, precision 83%, recall 83%, dan f1-score 82%. Meskipun perbedaannya tidak signifikan, hasil ini mengonfirmasi bahwa MobileNetV2 lebih efisien, terutama untuk aplikasi yang memerlukan kinerja cepat dan penggunaan sumber daya komputasi yang lebih rendah, seperti yang dijelaskan di studi [21]. VGG16, meskipun memiliki arsitektur yang lebih dalam dan kompleks, menunjukkan bahwa efisiensi komputasi bisa menjadi tantangan, terutama pada perangkat dengan sumber daya terbatas.

## 5 Kesimpulan

Dari evaluasi, hasil dan diskusi yang dilakukan maka dapat diambil kesimpulan untuk menilai kinerja dari arsitektur *MobileNetV2* dan VGG16. Hasil eksperimen perbandingan arsitektur ini mengkonfirmasi bahwa MobileNetV2 menghasilkan akurasi sebesar 84%, yang sejalan dengan penelitian M. Sandler [21] yang juga menemukan bahwa *MobileNetV2* lebih unggul dari VGG16 dalam hal efisiensi komputasi, yang juga didukung oleh penelitian lain, seperti yang dilakukan L. Rodrigues [19], di mana *MobileNetV2* menunjukkan kemampuan untuk mempertahankan akurasi tinggi dengan sumber daya komputasi yang lebih sedikit. Namun, penelitian S. Sennan [13] menunjukkan bahwa meskipun VGG16 lebih lambat, model ini tetap sangat efektif dalam menangani klasifikasi citra yang kompleks dengan lebih banyak parameter. Dalam penelitian ini tidak dijelaskan perbandingan evaluasi optimasi dalam masing masing arsitektur namun masalah optimasi dapat diselesaikan dengan pengoptimalan data preprocessing yang dilakukan. Untuk penelitian selanjutnya mungkin bisa membandingkan dalam segi optimasi masing masing arsitektur.

## Referensi

- [1] A. S. Paymode and V. B. Malode, "Transfer Learning for Multi-Crop Leaf Disease Image Classification using Convolutional Neural Network VGG," *Artif. Intell. Agric.*, vol. 6, pp. 23–33, 2022, doi: 10.1016/j.aiaa.2021.12.002.
- [2] B. Prasetyo, "Budi Daya Sayuran Organik di Pot",. Yogyakarta: Lily Publisher, 2013.
- [3] V. Srivastava and A. Khunteta, "Comparative Analysis of Leaf Classification and Recognition by Different SVM Classifiers," *Proc. Int. Conf. Inven. Res. Comput. Appl. ICIRCA 2018*, no. Icirca, pp. 626–631, 2018, doi: 10.1109/ICIRCA.2018.8596813.
- [4] I. A. Saidi, R. Azara, and E. Yanti, "Buku Ajar Pasca Panen dan Pengolahan Sayuran Daun", diterbitkan oleh Jl . Mojopahit 666 B Sidoarjo ISBN : 978-623-6292-21-1 Copyright © 2021 . Authors All rights reserved. 2021.
- [5] A. KP and J.Anitha, "Plant Disease Classification using Deep," *Proc. Int. Conf. Comput. Intell. Sustain. Eng. Solut. CISES 2022*, no. May, pp. 512–518, 2022, doi: 10.1109/CISES54857.2022.9844352.
- [6] J. Singh and H. Kaur, "Plant Disease Detection based on Region-based Segmentation and KNN classifier", vol. 30. Springer International Publishing, 2019. doi: 10.1007/978-3-030-00665-5\_154.
- [7] H. Nurrani, A. K. Nugroho, and S. Heranurweni, "a," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 7, no. 1, pp. 168–178, 2023, doi: 10.29207/resti.v7i1.4715.
- [8] V. Kumar, H. Arora, Harsh, and J. Sisodia, "ResNet-based Approach for Detection and Classification of Plant Leaf Diseases," *Proc. Int. Conf. Electron. Sustain. Commun. Syst. ICESC 2020*, no. Icesc, pp. 495–502, 2020, doi: 10.1109/ICESC48915.2020.9155585.
- [9] Y. Xu, X. Cong, Y. Zhai, Z. Gao, and H. Yu, "An Automatic Classification Grading of Spinach Seedlings Water Stress based on N-MobileNetXt," *Intell. Autom. Soft Comput.*, vol. 37, no. 3, pp. 3019–3037, 2023, doi: 10.32604/iasc.2023.040330.
- [10] S. Uddin, I. Haque, H. Lu, M. A. Moni, and E. Gide, "Comparative Performance Analysis of K-Nearest neighbour (KNN) Algorithm and its Different Variants for Disease Prediction," *Sci. Rep.*, vol. 12, no. 1, pp. 1–11, 2022, doi: 10.1038/s41598-022-10358-x.

- [11] S. Vallabhajosyula, V. Sistla, and V. K. K. Kolli, “*Transfer Learning-based Deep Ensemble Neural Network for Plant Leaf Disease Detection*,” *J. Plant Dis. Prot.*, vol. 129, no. 3, pp. 545–558, 2022, doi: 10.1007/s41348-021-00465-8.
- [12] M. Islam, N. J. Ria, J. F. Ani, A. K. M. Masum, S. Abujar, and S. A. Hossain, “*Deep Learning based Classification System for Recognizing Local Spinach*,” *Lect. Notes Networks Syst.*, vol. 249, pp. 1–14, 2022, doi: 10.1007/978-3-030-85365-5\_1.
- [13] S. Sennan, D. Pandey, Y. Alotaibi, and S. Alghamdi, “*A Novel Convolutional Neural Networks based Spinach Classification and Recognition System*,” *Comput. Mater. Contin.*, vol. 73, no. 1, pp. 343–361, 2022, doi: 10.32604/cmc.2022.028334.
- [14] K. Koyama, M. Tanaka, B. H. Cho, Y. Yoshikawa, and S. Koseki, “*Predicting Sensory Evaluation of Spinach Freshness using Machine Learning Model and Digital Images*,” *PLoS One*, vol. 16, no. 3 March, pp. 1–16, 2021, doi: 10.1371/journal.pone.0248769.
- [15] U. Barman, R. D. Choudhury, D. Sahu, and G. G. Barman, “*Comparison of Convolution Neural Networks for Smartphone Image based Real Time Classification of Citrus Leaf Disease*,” *Comput. Electron. Agric.*, vol. 177, no. January, p. 105661, 2020, doi: 10.1016/j.compag.2020.105661.
- [16] D. Sugiarto, J. Siswanto, M. F. Naufal, and B. Idrus, “*Mobile Application for Medicinal Plants Recognition from Leaf Image using Convolutional Neural Network*,” *Indones. J. Inf. Syst.*, vol. 5, no. 2, pp. 43–56, 2023, doi: 10.24002/ijis.v5i2.6633.
- [17] S. U. Habiba and M. K. Islam, “*Tomato Plant Diseases Classification using Deep Learning based Classifier from Leaves Images*,” *2021 Int. Conf. Inf. Commun. Technol. Sustain. Dev. ICICT4SD 2021 - Proc.*, pp. 82–86, 2021, doi: 10.1109/ICICT4SD50815.2021.9396883.
- [18] S. S. Chouhan, Ajay Kaul, and U. P. Singh, “*A Deep Learning Approach for The Classification of Diseased Plant Leaf Images*,” *Int. Conf. Commun. Electron. Syst. (ICCES 2019)*, vol. 194, no. Icces, pp. 701–710, 2019, doi: 10.1007/978-981-15-5971-6\_73.
- [19] L. Rodrigues, S. A. Magalhães, D. Q. da Silva, F. N. dos Santos, and M. Cunha, “*Computer Vision and Deep Learning as Tools for Leveraging Dynamic Phenological Classification In Vegetable Crops*,” *Agronomy*, vol. 13, no. 2, pp. 1–19, 2023, doi: 10.3390/agronomy13020463.
- [20] A. Sinha and R. Singh Shekhawat, “*A Novel Image Classification Technique for Spot and Blight Diseases in Plant Leaves*,” *Imaging Sci. J.*, vol. 68, no. 4, pp. 225–239, 2020, doi: 10.1080/13682199.2020.1865652.
- [21] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, “*MobileNetV2: Inverted Residuals and Linear Bottlenecks*,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 4510–4520, 2018, doi: 10.1109/CVPR.2018.00474.
- [22] T. Bezdán and N. Bačanić Džakula, “*Convolutional Neural Network Layers and Architectures*” no. July, pp. 445–451, 2019, doi: 10.15308/sinteza-2019-445-451.
- [23] C. Manliguez, “*Generalized Confusion Matrix for Multiple Classes Generalized Confusion Matrix for Multiple Classes The Total Numbers of False Negative ( TFN ), False Positive ( TFP ), and True Negative ( TTN ) for Each Class I will be Calculated based on the Generalized*,” no. November, pp. 5–7, 2016, doi: 10.13140/RG.2.2.31150.51523.