

Analisis Komparatif Kinerja MobileNetV2, VGG16, dan InceptionV3 dengan Pendekatan Fine Tuning pada Identifikasi Penyakit Daun Tomat

A Comparative Analysis of the Performance of MobileNetV2, VGG16, and InceptionV3 Using a Fine-Tuning Approach for Tomato Leaf Disease Identification

Eriska Setyaningtyas Rahmasari^{*1}, Afu Ichsan Pradana², Dwi Hartanti³

^{1,2,3} Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Duta Bangsa
Surakarta

e-mail: *eriskarahmasari@gmail.com

Abstrak - Teknik deteksi yang cepat dan tepat sangat penting karena penyakit daun tomat merupakan salah satu faktor yang dapat menurunkan kualitas dan kuantitas panen. Namun, sebagian besar deteksi penyakit daun tomat masih dilakukan secara manual menggunakan inspeksi mata yang subjektif dan rawan kesalahan. Akibatnya, teknologi computer vision diperlukan untuk memungkinkan kategorisasi penyakit secara otomatis. Untuk mendiagnosis penyakit daun tomat, penelitian ini membandingkan kinerja tiga arsitektur Convolutional Neural Network (CNN) MobileNetV2, VGG16, dan InceptionV3. Data yang digunakan adalah 9.799 foto daun tomat yang dikategorikan ke dalam sepuluh kelompok penyakit. Persiapan data, pelatihan model menggunakan transfer learning dan fine-tuning, serta penilaian menggunakan metrik akurasi, presisi, recall, dan F1-score merupakan beberapa langkah dalam proses penelitian. Berdasarkan hasil pengujian, VGG16 memiliki akurasi tertinggi sebesar 98%, diikuti oleh MobileNetV2 sebesar 87% dan InceptionV3 sebesar 94%. Dibandingkan dengan model lain, VGG16 juga menghasilkan nilai akurasi, recall, dan F1 score terbaik.

Kata kunci – komponen ; Fine Tuning, MobileNetV2, VGG16, InceptionV3

Abstract - Rapid and precise detection techniques are essential since tomato leaf diseases are one of the elements that might lower the harvest's quality and quantity. However, the majority of tomato leaf disease detection is still done by hand using subjective and error-prone eye inspection. As a result, computer vision technology is required to enable automated illness categorization. In order to diagnose tomato leaf diseases, this study compares the performance of three Convolutional Neural Network (CNN) architectures: MobileNetV2, VGG16, and InceptionV3. Roboflow provided the data, which includes 9,799 tomato leaf photos categorized into ten disease groups. Data preparation, model training utilizing transfer learning and fine-tuning, and assessment using accuracy, precision, recall, and F1-score metrics are all steps in the research process. According to the test findings, VGG16 had the greatest accuracy of 98%, followed by MobileNetV2 at 87% and InceptionV3 at 94%. In comparison to the other models, VGG16 also generated the best accuracy, recall, and F1-score values.

Keywords – components; Fine Tuning, MobileNetV2, VGG16, InceptionV3

I. PENDAHULUAN

Tomat merupakan komoditas hortikultura yang sangat berharga dan banyak ditanam di seluruh Indonesia. Namun, produksi tomat seringkali menurun akibat serangan serangga dan penyakit, terutama pada daun, yang dapat menghambat perkembangan tanaman dan menurunkan kualitas serta hasil panen [1]. Saat ini, petani dan ahli masih sebagian besar mengidentifikasi penyakit daun tomat dengan inspeksi visual, yang membuat prosesnya subjektif, rentan terhadap kesalahpahaman, dan memakan waktu [2]. Untuk meningkatkan pengendalian penyakit sejak dini, situasi ini menyoroti perlunya metode deteksi penyakit yang lebih objektif, cepat, dan akurat.

Melalui analisis citra digital, sistem deteksi penyakit tanaman otomatis dapat dikembangkan berkat kemajuan dalam visi komputer dan pembelajaran mendalam. *Convolutional Neural Network* (CNN) adalah metode yang populer karena kinerjanya baik dalam kategorisasi gambar dan dapat secara otomatis mengekstrak karakteristik visual [3]. Namun, transfer learning merupakan pendekatan yang lebih efektif, karena pelatihan CNN dari awal membutuhkan kumpulan data yang besar dan komputer yang canggih [4]. Strategi fine tuning digunakan untuk menyesuaikan model dengan fitur visual penyakit daun tomat dengan melatih ulang beberapa lapisan akhir jaringan, sehingga representasi fitur akhir menjadi lebih relevan dengan kumpulan data target.

Sejumlah penelitian terdahulu menunjukkan bahwa arsitektur CNN seperti InceptionV3, VGG16, dan MobileNetV2 memiliki performa yang baik dalam klasifikasi penyakit daun tomat. Nurdin, Kartika, dan Najaf (2024) memperoleh akurasi 93,8% menggunakan InceptionV3[5], Pradana dkk. (2023) mencapai akurasi pengujian 91% dan akurasi validasi 92% dengan VGG16 [6], sedangkan Aryaputra, Widodo, dan Sanjaya (2025) memperoleh akurasi 88% menggunakan MobileNetV2[7]. Meskipun demikian, sebagian besar penelitian sebelumnya hanya berfokus pada satu arsitektur tertentu atau membandingkan model pada skenario yang berbeda, sehingga performa ketiga arsitektur belum dapat dibandingkan secara langsung pada dataset yang sama. Selain itu, evaluasi komparatif dengan pendekatan fine tuning pada klasifikasi penyakit daun tomat masih terbatas, sehingga belum diketahui model mana yang paling optimal.

Berdasarkan kesenjangan tersebut, penelitian ini bertujuan melakukan analisis komparatif terhadap MobileNetV2, VGG16, dan InceptionV3 menggunakan teknik fine tuning pada klasifikasi penyakit daun tomat. Ketiga model dipilih karena mewakili karakteristik CNN yang berbeda, yaitu MobileNetV2 yang ringan dan efisien, VGG16 yang dalam dan konsisten dalam ekstraksi fitur, serta InceptionV3 yang unggul dalam ekstraksi fitur multiskala. Penerapan metode fine tuning yang konsisten pada ketiga model, yang memungkinkan evaluasi yang lebih objektif, adalah hal yang membuat penelitian ini inovatif. Untuk menawarkan pandangan yang lebih lengkap tentang kinerja model dalam mengidentifikasi arsitektur CNN terbaik untuk deteksi penyakit daun tomat, penelitian ini juga memeriksa akurasi, presisi, recall, dan F1 score.

II. TINJAUAN TEORI


2.1. Penelitian Terdahulu

Beberapa penelitian sebelumnya telah mengkaji penerapan algoritma deep learning, khususnya *Convolutional Neural Network* (CNN), dalam mendeteksi dan mengklasifikasikan

penyakit pada daun tomat. Dengan tingkat akurasi 93,8% dan hasil terbaik menggunakan optimizer Adam, Nurdin, Kartika, dan Najaf (2024) menunjukkan efektivitas arsitektur InceptionV3 dalam mengidentifikasi pola rumit penyakit daun tomat [5]. Sementara itu, Pradana dkk. (2023) menggunakan CNN dengan arsitektur VGG16 untuk membuat sistem klasifikasi penyakit tanaman tomat yang memiliki akurasi pengujian 91% dan akurasi validasi 92% [6]. Dalam penelitian yang berbeda, Aryaputra, Widodo, dan Sanjaya (2025) mengklasifikasikan penyakit daun tomat menggunakan arsitektur MobileNetV2, mencapai akurasi keseluruhan 88% [7].

2.2. Convolutional Neural Network (CNN)

Dalam pemrosesan citra digital, CNN adalah salah satu teknik pembelajaran mendalam yang paling populer [8]. CNN berguna untuk aplikasi klasifikasi citra karena dapat secara otomatis mengidentifikasi dan mengekstrak karakteristik visual dari gambar tanpa memerlukan ekstraksi fitur manusia [9]. Lapisan konvolusi, pooling, dan fully linked adalah tiga lapisan utama yang membentuk arsitektur CNN. Untuk membuat peta fitur, lapisan konvolusi menggunakan filter atau kernel untuk mengekstrak informasi dari gambar. Lapisan pooling kemudian digunakan untuk mengurangi dimensi data sambil mempertahankan informasi penting, yang meningkatkan efisiensi komputasi. Fitur yang terkumpul kemudian diratakan menjadi vektor satu dimensi dan dimasukkan ke dalam lapisan yang terhubung sepenuhnya untuk klasifikasi. Kelas keluaran ditentukan pada lapisan terakhir menggunakan fungsi aktivasi, seperti softmax, berdasarkan nilai probabilitas tertinggi. Keuntungan CNN adalah dapat melakukan ekstraksi fitur dan klasifikasi dalam model yang sama. Akibatnya, CNN sering digunakan dalam berbagai investigasi klasifikasi gambar, seperti diagnosis penyakit tanaman menggunakan foto daun. Gambar 1 menggambarkan arsitektur dasar CNN.




Gambar 1. Arsitektur *Convolutional Neural Network*

2.3. Fine Tuning

Metode pelatihan canggih untuk model CNN yang disebut "penyetelan halus" melibatkan pelatihan ulang lapisan jaringan individual terutama lapisan terakhir menggunakan kumpulan data yang unik untuk pekerjaan klasifikasi yang sedang dilakukan. Tujuan dari metode ini adalah untuk memodifikasi representasi fitur model saat ini sehingga lebih mencerminkan fitur data penelitian.

Model dapat meningkatkan kinerja klasifikasinya pada kumpulan data target dengan mempelajari pola visual yang lebih tepat melalui prosedur penyetelan halus. Karena telah berhasil meningkatkan kinerja model, metode ini sering digunakan dalam berbagai penelitian pengolahan gambar, terutama ketika objek yang dikategorikan memiliki sifat visual yang unik dan rumit.[4].




Gambar 2. Arsitektur *Fine Tuning*

Arsitektur umum dari proses fine tuning model CNN ditunjukkan pada Gambar 2. Dalam pendekatan ini, beberapa lapisan jaringan dipertahankan untuk menjaga kemampuan ekstraksi fitur yang sudah ada pada model, sementara lapisan lainnya dilatih ulang agar dapat menyesuaikan diri dengan karakteristik kumpulan data yang digunakan. Hasilnya, model tersebut dapat menghasilkan representasi fitur yang lebih sesuai untuk mendukung proses klasifikasi secara optimal.

2.4. MobilenetV2

Arsitektur Convolutional Neural Network (CNN) yang disebut MobileNetV2 dibuat untuk mengungguli arsitektur CNN tradisional dalam klasifikasi sambil menggunakan lebih sedikit sumber daya komputasi dan parameter [10]. Untuk meningkatkan efisiensi proses ekstraksi fitur, Sandler dkk. menggabungkan ide ide konvolusi terpisah kedalam dan blok residual invers untuk menciptakan desain ini.



Gambar 3. Arsitektur Mobilenet V2

Berdasarkan Gambar 3, MobileNetV2 terdiri dari beberapa blok utama yang diawali dengan lapisan konvolusi awal, kemudian dilanjutkan dengan serangkaian *bottleneck residual blocks*. Pada setiap blok, fitur terlebih dahulu diperluas, diproses menggunakan *depthwise convolution*, kemudian diproyeksikan kembali ke dimensi yang lebih kecil (*projection layer*). Struktur ini memungkinkan model mempertahankan informasi penting sekaligus mengurangi kompleksitas komputasi.

Keunggulan utama MobileNetV2 terletak pada penggunaan konvolusi yang dapat dipisahkan secara kedalam *depthwise separable convolutions*, yang memisahkan proses konvolusi spasial dan konvolusi kanal, sehingga secara signifikan mengurangi jumlah

parameter dan waktu komputasi[11]. Akibatnya, MobileNetV2 banyak digunakan dalam aplikasi klasifikasi gambar yang membutuhkan model ringan, termasuk klasifikasi penyakit tanaman berbasis citra daun. Dalam berbagai penelitian, arsitektur ini telah menunjukkan kinerja yang kompetitif dengan ukuran model yang relatif kecil, sehingga cocok untuk diimplementasikan pada perangkat seluler dan sistem *Internet of Things* (IoT).

2.5. VGG16

Kelompok Geometri Visual (VGG) Universitas Oxford menciptakan Jaringan Neural Konvolusional (CNN) VGG16. Model ini sering digunakan dalam penelitian klasifikasi gambar karena dapat secara efisien mengekstrak fitur visual dan berkinerja baik dalam berbagai skenario klasifikasi [12]. Model ini termasuk dalam kelompok *pre trained model* yang telah dilatih pada dataset ImageNet. VGG16 terdiri dari tiga lapisan terhubung penuh, tiga belas lapisan konvolusional, dan enam belas lapisan berbobot yang ditumpuk secara berurutan menggunakan filter konvolusional 3x3 [13]. Manfaat utama VGG16 adalah desain arsitekturnya yang sederhana dan seragam, yang memungkinkannya untuk secara progresif mengekstrak isyarat visual dari elemen sederhana seperti tepi dan tekstur hingga elemen yang lebih rumit.




Gambar 4. Arsitektur VGG 16

Desain VGG16, yang mengurangi dimensi fitur dengan menggunakan lapisan max pooling setelah beberapa blok konvolusi, terlihat pada Gambar 4. Keluaran lapisan konvolusi diberikan ke lapisan *fully connected* dan *softmax* untuk menghasilkan prediksi kelas setelah ekstraksi fitur selesai. Klasifikasi penyakit tanaman berdasarkan gambar daun adalah salah satu dari banyak aplikasi pengenalan pola dan klasifikasi gambar yang mendapat manfaat dari kerangka kerja sistematis VGG16.

2.6. InceptionV3

Arsitektur *Convolutional Neural Network* (CNN) yang disebut InceptionV3 diciptakan untuk meningkatkan kinerja kategorisasi gambar sambil tetap menjaga efisiensi komputasi. Modul Inception, yang memungkinkan pemrosesan fitur secara simultan pada beberapa skala, digunakan dalam arsitektur ini untuk memberikan ekstraksi fitur yang lebih efisien. Seperti yang ditunjukkan pada Gambar 5, InceptionV3 terdiri dari beberapa modul Inception yang melakukan ekstraksi fitur secara paralel menggunakan filter konvolusional dengan ukuran yang berbeda, sehingga mampu mengenali pola visual yang lebih beragam dan kompleks[14].



Gambar 5. Arsitektur Inception V3

Pendekatan ini mampu mengumpulkan informasi visual pada berbagai tingkat kompleksitas, dari karakteristik dasar seperti tepi dan tekstur hingga pola yang lebih rumit, dengan menggunakan ukuran filter yang berbeda secara bersamaan. Selain itu, InceptionV3 dirancang untuk memanfaatkan pendekatan faktor konvolusi untuk meminimalkan jumlah parameter, menjaga efisiensi jaringan tanpa mengorbankan kinerja model.[15].

III. METODE

Tinjauan pustaka, pengumpulan dataset, persiapan data, pelatihan model, penilaian model, dan analisis hasil merupakan langkah langkah yang membentuk metodologi penelitian ini. Gambar 6 menggambarkan alur penelitian. Infrastruktur Google Colab dan bahasa pemrograman Python digunakan untuk seluruh prosedur pelatihan dan penilaian model.



Gambar 6. Tahapan Penelitian

Platform Roboflow menyediakan dataset, yang mencakup 9.799 foto daun tomat yang dibagi menjadi sepuluh kategori penyakit daun tomat. Diharapkan bahwa variasi pencahayaan, sudut pengambilan gambar, dan latar belakang dataset akan membantu model dalam mempelajari karakteristik visual secara lebih efisien dan meningkatkan kemampuannya untuk melakukan generalisasi ke data baru.


Semua foto menerima pra pemrosesan, yang mencakup augmentasi data, normalisasi nilai piksel, dan penskalaan gambar menjadi 224 x 224 piksel, sebelum dimulainya prosedur pelatihan. Selanjutnya, transfer learning dan fine tuning digunakan untuk menguji tiga arsitektur CNN: MobileNetV2, VGG16, dan InceptionV3. Metrik seperti akurasi, presisi, recall, dan F1 score digunakan untuk menilai kinerja model. Arsitektur optimal untuk mengidentifikasi penyakit daun tomat kemudian diidentifikasi dengan membandingkan hasil penilaian dari ketiga model tersebut.

IV. HASIL DAN PEMBAHASAN


Hasil pelatihan dan evaluasi dari tiga arsitektur MobileNetV2, VGG16, dan InceptionV3 yang dilatih menggunakan pendekatan fine tuning pada dataset penyakit daun tomat ditunjukkan pada bagian ini. Berdasarkan akurasi, presisi, recall, dan F1 score, kemampuan setiap model untuk mengkategorikan penyakit daun tomat dievaluasi. Selain itu, analisis grafik akurasi dan loss dilakukan untuk melacak pembelajaran setiap model selama pelatihan.

3.1. MobilenetV2

Setelah dilakukan proses pelatihan menggunakan arsitektur MobileNetV2, model dilatih selama 100 epoch yang terdiri dari 50 epoch pelatihan awal dan 50 epoch fine tuning dengan membuka 20 lapisan terakhir untuk menyesuaikan model terhadap karakteristik dataset penyakit daun tomat. Hasil pelatihan menghasilkan grafik akurasi dan grafik loss yang digunakan untuk mengevaluasi model selama pelatihan, seperti yang ditunjukkan pada gambar 7 dan gambar 8.



Gambar 7. Grafik Akurasi Model Mobilenet V2



Gambar 8. Grafik Loss Model Mobilenet V2

Berdasarkan grafik akurasi, terlihat bahwa akurasi training dan validation meningkat cukup cepat pada epoch awal, lalu mulai melandai dan stabil setelah sekitar epoch ke 20. Kurva training accuracy terus naik hingga berada di kisaran 0,90 - 0,91, sedangkan validation accuracy berada di kisaran 0,86 - 0,88. Pola ini menunjukkan bahwa selama fase pelatihan, model mampu memahami dengan benar ciri ciri foto penyakit daun tomat. Nilai loss pelatihan dan loss validasi terus menurun dari awal pelatihan hingga epoch terakhir, seperti yang ditunjukkan oleh grafik loss. Sementara loss validasi menurun menjadi sekitar 0,37 - 0,38, loss pelatihan turun dari jumlah yang relatif tinggi menjadi sekitar 0,30. Penurunan loss yang konsisten ini menunjukkan bahwa proses pembelajaran model berjalan dengan baik dan semakin mahir dalam meminimalkan kesalahan prediksi.


31/31										15s 213ms/step							
[[98 2 2 2 5 0 0 1 1 0]																	
[4 75 9 10 7 3 6 0 0 1]																	
[0 2 80 1 0 0 1 0 0 0]																	
[0 0 0 78 2 0 1 0 2 0]																	
[5 2 0 3 94 2 1 0 0 1]																	
[1 0 1 3 2 89 5 1 0 1]																	
[4 3 1 1 2 10 75 0 0 7]																	
[0 0 0 1 0 0 1 86 2 0]																	
[0 0 0 1 3 0 0 1 81 0]																	
[0 0 0 0 0 2 3 0 0 93]]																	
precision										recall		f1-score		support			
0										0.88		0.88		0.88		111	
1										0.89		0.65		0.75		115	
2										0.86		0.95		0.90		84	
3										0.78		0.94		0.85		83	
4										0.82		0.87		0.84		108	
5										0.84		0.86		0.85		103	
6										0.81		0.73		0.77		103	
7										0.97		0.96		0.96		90	
8										0.94		0.94		0.94		86	
9										0.90		0.95		0.93		98	
accuracy														0.87		981	
macro avg										0.87		0.87		0.87		981	
weighted avg										0.87		0.87		0.86		981	

Gambar 9. Hasil Akurasi Model Mobilenet V2


Arsitektur MobileNetV2 digunakan untuk melatih data penyakit daun tomat, seperti yang ditunjukkan pada Gambar 9, yang menunjukkan akurasi sebesar 87% dengan presisi, recall, dan F1 score yang cukup seimbang. Meskipun masih ada beberapa kesalahan prediksi pada kelas kelas tertentu dengan ciri visual yang serupa, hal ini menunjukkan bahwa model tersebut dapat mendiagnosis penyakit daun tomat dengan cukup efektif.

3.2. VGG16

Setelah dilakukan proses pelatihan menggunakan arsitektur VGG16, model dilatih selama 100 epoch yang terdiri dari 50 epoch pelatihan awal dan 50 epoch fine tuning dengan membuka blok konvolusi ke 5 untuk dilatih kembali. Untuk memungkinkan model memodifikasi bobot pada lapisan akhir agar merepresentasikan fitur fitur dari dataset penyakit daun tomat yang digunakan dalam penelitian ini, prosedur fine tuning dilakukan. Seperti yang terlihat pada Gambar 9 dan 10, hasil pelatihan menghasilkan grafik akurasi dan loss yang digunakan untuk merotasi model selama pelatihan.



Gambar 10. Grafik Akurasi Model VGG16



Gambar 11. Grafik Loss Model VGG16

Menurut grafik akurasi pada Gambar 10, akurasi pelatihan dan validasi bervariasi secara stabil dari awal pelatihan hingga stabil pada periode terakhir. Akurasi validasi sekitar 0,90, tetapi akurasi pelatihan sekitar 0,87. Ini menunjukkan bahwa pola gambar penyakit daun tomat mungkin dipelajari secara efektif oleh model VGG16. Grafik kerugian pelatihan dan kerugian validasi pada Gambar 11 keduanya menurun secara progresif sepanjang fase pelatihan. Pada akhir periode, kerugian validasi sekitar 0,32 dan kerugian pelatihan sekitar 0,37. Penurunan kerugian yang konsisten ini menunjukkan bahwa model semakin baik dalam mengurangi kesalahan prediksi.


31/31	10s 287ms/step									
[[110	1	0	0	0	0	0	0	0	0]	
[1 106	1	0	2	1	4	0	0	0	0]	
[0 0	82	0	0	0	1	1	0	0	0]	
[0 0	0	81	1	1	0	0	0	0	0]	
[0 0	0	0	107	0	0	0	0	0	1]	
[0 0	0	0	0	102	1	0	0	0	0]	
[0 0	0	0	0	2	101	0	0	0	0]	
[1 0	0	0	0	0	0	89	0	0	0]	
[0 0	0	0	0	0	0	0	86	0	0]	
[0 0	0	0	0	1	0	0	0	97]		
	precision		recall		f1-score		support			
	0	0.98	0.99	0.99	0.99	111				
	1	0.99	0.92	0.95	0.95	115				
	2	0.99	0.98	0.98	0.98	84				
	3	1.00	0.98	0.99	0.99	83				
	4	0.97	0.99	0.98	0.98	108				
	5	0.95	0.99	0.97	0.97	103				
	6	0.94	0.98	0.96	0.96	103				
	7	0.99	0.99	0.99	0.99	90				
	8	1.00	1.00	1.00	1.00	86				
	9	0.99	0.99	0.99	0.99	98				
accuracy					0.98	981				
macro avg		0.98	0.98	0.98	0.98	981				
weighted avg		0.98	0.98	0.98	0.98	981				


Gambar 12. Hasil Akurasi Model VGG16

Model VGG16 memperoleh akurasi 98% pada data uji, menurut temuan penilaian yang ditunjukkan pada Gambar 12. Selain itu, model ini berkinerja sangat baik dalam mendiagnosis penyakit daun tomat, seperti yang terlihat dari rata-rata akurasi, recall, dan F1 score yang semuanya mencapai 0,98. Nilai tinggi untuk ketiga kriteria tersebut menunjukkan bahwa model ini dapat mendeteksi semua jenis penyakit yang diuji secara andal selain membuat prediksi yang akurat.

3.3. InceptionV3

Mengikuti prosedur pelatihan arsitektur InceptionV3, model dilatih selama 100 epoch, termasuk 50 epoch pelatihan awal dan 50 epoch penyempurnaan dengan membuka 20 lapisan terakhir untuk pelatihan tambahan. Seperti yang terlihat pada Gambar 12 dan 13, hasil pelatihan menghasilkan grafik akurasi dan grafik kerugian yang digunakan untuk memutar model selama pelatihan.

**Gambar 13.** Grafik Akurasi Model Inception V3



Gambar 14. Grafik Akurasi Model Inception V3

Menurut Gambar 13, grafik akurasi menunjukkan bahwa akurasi pelatihan dan validasi meningkat secara stabil selama fase pelatihan hingga mencapai titik stabil pada epoch terakhir. Akurasi validasi sekitar 0,88, sedangkan nilai akurasi pelatihan sekitar 0,89. Model InceptionV3 mampu mempelajari ciri ciri penyakit daun tomat dan memiliki kapasitas generalisasi yang cukup kuat untuk memvalidasi data, seperti yang terlihat dari tren kurva kedua yang praktis konstan sepanjang prosedur pelatihan. Kerugian pelatihan dan validasi menurun drastis di awal pelatihan sebelum secara bertahap menurun hingga mencapai titik stabil di epoch terakhir, seperti yang terlihat pada grafik kerugian Gambar 14. Kerugian validasi sekitar 0,37, sedangkan kerugian pelatihan sekitar 0,35. Model mampu mengurangi kesalahan prediksi dan tidak mengalami overfitting secara signifikan selama fase pelatihan, seperti yang terlihat dari perbedaan yang sangat kecil antara kedua kurva. Penurunan kerugian yang stabil lebih lanjut menunjukkan bahwa kemampuan model untuk mengidentifikasi pola penyakit pada daun tomat berhasil ditingkatkan melalui prosedur fine tuning.

31/31 19s 433ms/step

[[104	2	2	0	3	0	0	0	0	0]
[0	100	2	2	4	4	2	1	0	0]
[0	2	80	1	0	0	1	0	0	0]
[0	1	0	76	5	0	0	0	1	0]
[3	1	0	1	101	0	2	0	0	0]
[0	0	0	0	0	102	1	0	0	0]
[0	0	0	0	0	8	93	0	0	2]
[0	0	0	1	0	2	1	86	0	0]
[0	0	0	0	1	0	0	0	85	0]
[0	0	1	0	0	2	3	0	0	92]]
		precision		recall		f1-score		support	
	0	0.97		0.94		0.95		111	
	1	0.94		0.87		0.90		115	
	2	0.94		0.95		0.95		84	
	3	0.94		0.92		0.93		83	
	4	0.89		0.94		0.91		108	
	5	0.86		0.99		0.92		103	
	6	0.90		0.90		0.90		103	
	7	0.99		0.96		0.97		90	
	8	0.99		0.99		0.99		86	
	9	0.98		0.94		0.96		98	
accuracy						0.94		981	
macro avg		0.94		0.94		0.94		981	
weighted avg		0.94		0.94		0.94		981	

Gambar 15. Hasil Akurasi Model Inception V3

Model InceptionV3 menunjukkan akurasi 94% pada data uji, menurut temuan penilaian yang ditunjukkan pada Gambar 15. Selain itu, model tersebut berkinerja baik dan konsisten di semua kategori penyakit daun tomat, dengan akurasi, recall, dan F1 score rata rata 0,94.

Pengukuran akurasi, presisi, recall, dan F1 Score digunakan untuk mengevaluasi kinerja setiap model secara detail menggunakan data uji. Tabel 1 menampilkan temuan penilaian untuk ketiga model yang digunakan dalam penelitian ini.

Tabel 1. Hasil Evaluasi Model

No	Model	Accuracy (%)	Precision	Recall	F1 Score
1	Mobilenet V2	87	0,87	0,87	0,87
2	VGG16	98	0,98	0,98	0,98
3	Inception V3	94	0,94	0,94	0,94

Ketiga model tersebut menunjukkan kemampuan yang kuat dalam mengklasifikasikan penyakit daun tomat, berdasarkan temuan penilaian pada Tabel 1. Dengan akurasi 98% dan presisi, recall, serta F1 score sebesar 0,98, VGG16 menunjukkan kinerja terbaik. Temuan ini menunjukkan bahwa VGG16 mengungguli model lain dalam mengekstraksi karakteristik visual penyakit daun tomat. Dengan akurasi 94% dan F1 score sebesar 0,94, InceptionV3 berada di urutan kedua, sedangkan MobileNetV2 memiliki akurasi 87% dan F1 score sebesar 0,87. Dengan keuntungan efisiensi komputasi yang lebih besar, MobileNetV2 menunjukkan kemampuan klasifikasi yang layak meskipun kinerjanya lebih buruk daripada VGG16 dan InceptionV3.

V. KESIMPULAN DAN SARAN

Temuan penelitian menunjukkan bahwa arsitektur MobileNetV2, VGG16, dan InceptionV3 berkinerja baik dalam klasifikasi penyakit daun tomat ketika pendekatan fine tuning diterapkan. Menurut temuan pengujian, VGG16 berkinerja terbaik dengan akurasi 98%, diikuti oleh MobileNetV2 sebesar 87% dan InceptionV3 sebesar 94%. Selain itu, nilai akurasi, recall, dan F1 score yang diperoleh menunjukkan bahwa VGG16 terbukti unggul dari dua model lainnya dalam mengidentifikasi berbagai jenis penyakit daun tomat. Akibatnya, VGG16 disarankan sebagai arsitektur terbaik untuk mengkategorikan penyakit daun tomat pada dataset penelitian. Disarankan untuk menggunakan dataset dengan kuantitas dan keragaman gambar yang lebih besar untuk penelitian selanjutnya, serta strategi augmentasi yang lebih beragam.

VI. DAFTAR PUSTAKA

- [1] H. N. Orun, "Klasifikasi Penyakit Daun Tomat Menggunakan VGG Berbasis Website Classification of Tomato Leaf Diseases Using Web- Based VGG," *MARAS*, vol. 2, no. 3, pp. 1306–1312, 2024, doi: <https://doi.org/10.60126/maras.v2i3.367>.
- [2] P. A. Azli, A. Syahrani, and G. Y. Swara, "Segmentasi Citra Daun Tomat untuk Klasifikasi Penyakit Tanaman Menggunakan Support Vector Machine (SVM)," *J. Inform. J. Pengemb. IT*, vol. 10, no. 4, pp. 997–1008, 2025, doi: [10.30591/jpit.v10i4.9404](https://doi.org/10.30591/jpit.v10i4.9404).
- [3] R. Soekarta *et al.*, "IMPLEMENTASI DEEP LEARNING UNTUK DETEKSI JENIS OBAT proses kehidupan dan merupakan senyawa tubuh (Prabowo , 2021). Saat ini berbagai jenis dibedakan beberapa bentuk sediaan obat . Dalam lingkungan farmasi yang untuk otomatisasi dalam pengelolaan obat s," *JIKA*, vol. 7, no. 4, pp. 455–464, 2023, doi: <https://doi.org/10.31000/jika.v7i4.9751>.
- [4] A. W. Salehi, S. Khan, G. Gupta, B. I. Alabdullah, and A. Almjally, "A Study of CNN and

- Transfer Learning in Medical Imaging : Advantages , Challenges , Future Scope,” *Sustainability*, vol. 15, no. 7, p. 5930, 2023, doi: <https://doi.org/10.3390/su15075930>.
- [5] A. Nurdin, D. Satria, Y. Kartika, A. Rezha, and E. Najaf, “Klasifikasi Penyakit Daun Tomat Dengan Metode Convolutional Neural Network Menggunakan Arsitektur Inception-V3,” *JIF*, vol. 12, no. 1, pp. 1–6, 2024, doi: <https://doi.org/10.33884/jif.v12i02.9162>.
- [6] M. A. Pradana, R. I. Maulana, R. S. Putra, and F. Tri, “Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN) VGG16,” *KERNEL*, vol. 4, no. 2, pp. 61–69, 2023, doi: [10.31284/j.kernel.2023.v4i2.6829](https://doi.org/10.31284/j.kernel.2023.v4i2.6829).
- [7] A. S. Adis Prima Aryaputra, Danang Wahyu Widodo, “Klasifikasi Penyakit Daun Tomat Menggunakan Algoritma CNN Mobilenet V2,” *INOTEK*, vol. 9, no. 1, pp. 102–108, 2025, doi: <https://doi.org/10.29407/s37pzf98>.
- [8] K. D. L. S. R and A. D. Hartanto, “Studi Literatur Mengenai Klasifikasi Citra Kucing Dengan Menggunakan Deep Learning : Convolutional Neural Network (CNN),” *JEECOM*, vol. 6, no. 1, pp. 129–137, 2024, doi: [10.33650/jeecom.v4i2](https://doi.org/10.33650/jeecom.v4i2).
- [9] A. R. M. Antony Christ Hartono, “Penerapan Transfer Learning MobileNetV2 Pada Klasifikasi Citra Jenis Buah-Buahan,” *JISAD*, vol. 3, no. 2, pp. 103–111, 2025, doi: [10.26905/jisad.v3i2.16187](https://doi.org/10.26905/jisad.v3i2.16187).
- [10] D. Penyakit, D. Jagung, Y. A. Sitorus, Y. A. Sari, and S. Adinugroho, “Evaluasi Komparatif Arsitektur Lightweight CNN , MobileNetV2 , dan,” *JPTIIK*, vol. 9, no. 8, pp. 1–6, 2025, doi: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/15217>.
- [11] N. N. Tiara Dwi Lestari, “Perbandingan vgg16, vgg19, mobilenet dan mobilenetv2 untuk klasifikasi beras berdasarkan citra 1),” *RABIT*, vol. 11, no. 1, pp. 1368–1380, 2026, doi: [DOI : https://doi.org/10.36341/rabit.v11i1.7338](https://doi.org/10.36341/rabit.v11i1.7338).
- [12] M. K. Insani and D. B. Santoso, “Perbandingan Kinerja Model Pre-Trained CNN (VGG16 , Wajah pada Sistem Absensi Karyawan Abstrak,” *JIMIK*, vol. 5, no. 3, pp. 2612–2622, 2024, doi: <https://doi.org/10.35870/jimik.v5i3.925>.
- [13] H. Ety Sutanty, Maukar, Dina Kusuma Astuti, “Penerapan Model Arsitektur VGG16 Untuk Klasifikasi Jenis Sampah,” *DECODE*, vol. 3, no. 2, pp. 407–419, 2023, doi: <https://doi.org/10.51454/decode.v3i2.331>.
- [14] D. Prasetya, B. Hanggara, R. Naufaldihanif, A. Clark, P. Wijaya, and A. Ibrahim, “KLASIFIKASI KONDISI KEBERSIHAN SUNGAI DARI CITRA DIGITAL MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK DENGAN ALGORITMA INCEPTION V3 DAN XCEPTION,” *JATI*, vol. 9, no. 3, pp. 5338–5343, 2025, doi: <https://doi.org/10.36040/jati.v9i3.14123>.
- [15] B. P. H. Aryo Bimo Wicaksono, “Analisis performa arsitektur cnn inceptionv3 dan vgg16 dalam klasifikasi deteksi kanker otak,” *JIPi*, vol. 10, no. 2, pp. 938–948, 2025, doi: <https://doi.org/10.29100/jipi.v10i2.6090>.