



## d Penggunaan Transfer Learning untuk Peningkatan Akurasi Deteksi Penyakit Tanaman Bunga

Enteng Hardiansyah<sup>1\*</sup>, Lailan Sofinah Haharap<sup>2</sup>, Muhammad Farros Atiqi<sup>3</sup>

<sup>1,2</sup> Ilmu Komputer, Fakultas Sains dan Teknologi, Universitas Islam Negeri Sumatera Utara, Indonesia

<sup>3</sup> Teknologi Informasi, Fakultas Ilmu Komputer dan Teknologi Indormasi, Universitas Muhammadiyah Sumatra Utara, Indonesia

Email: [entenghardiansyah@gmail.com](mailto:entenghardiansyah@gmail.com)<sup>1</sup>, [farros100905@gmail.com](mailto:farros100905@gmail.com)<sup>2</sup>, [lailansofinah@uinsu.ac.id](mailto:lailansofinah@uinsu.ac.id)<sup>3</sup>

\*Penulis korespondensi : [entenghardiansyah@gmail.com](mailto:entenghardiansyah@gmail.com)

**Abstract.** Flower disease detection is a common challenge in modern agriculture. Various factors, such as changes in leaf color, shape, petal structure, and environmental conditions, make it difficult to achieve high accuracy with conventional models. Transfer learning is an effective solution to improve model performance in image detection, especially when available data is limited. This study used several pre-trained models, namely VGG16, ResNet50, and EfficientNet-B0, to detect three types of flower diseases: black spot on roses, white powdery mildew, and leaf rust. The process included data processing, increasing the data volume, model training, and result verification. The results showed that the EfficientNet-B0 model provided the highest accuracy of 97.2%, significantly better than the CNN model created from scratch with an accuracy of 85.1%. This study proves that the transfer learning method is very effective in improving the accuracy of flower disease detection. These results confirm that transfer learning is effective for detecting plant diseases with higher accuracy, especially when the dataset is limited.

**Keywords:** Computer Vision, Deep Learning, Flowering Plants, Plant Disease Detection, Transfer Learning.

**Abstrak.** Deteksi penyakit pada tanaman bunga merupakan tantangan yang sering dihadapi dalam pertanian modern. Berbagai faktor seperti perubahan warna daun, bentuk, struktur kelopak, serta kondisi lingkungan menyebabkan kesulitan dalam mendapatkan akurasi yang tinggi dengan model konvensional. Transfer learning menjadi solusi yang efektif untuk meningkatkan kinerja model dalam mendeteksi gambar, terutama ketika data yang tersedia terbatas. Penelitian ini menggunakan beberapa model yang sudah dilatih sebelumnya, yaitu VGG16, ResNet50, dan EfficientNet-B0, untuk mendeteksi tiga jenis penyakit pada bunga, yaitu spot hitam pada rose, mildew serbuk putih, dan rust daun. Proses yang dilakukan mencakup pengolahan data, peningkatan jumlah data, pelatihan model, serta pengecekan hasil. Hasil menunjukkan bahwa model EfficientNet-B0 memberikan akurasi tertinggi, yaitu 97,2%, yang jauh lebih baik dibandingkan model CNN yang dibuat dari awal dengan akurasi 85,1%. Penelitian ini membuktikan bahwa metode transfer learning sangat efektif dalam meningkatkan akurasi deteksi penyakit pada tanaman bunga. Hasil ini mengonfirmasi bahwa transfer learning efektif untuk mendeteksi penyakit tanaman dengan akurasi yang lebih tinggi, terutama ketika dataset terbatas.

**Kata kunci:** Computer Vision, Deep Learning, Deteksi Penyakit Tanaman, Tanaman Bunga, Transfer Learning.

### 1. LATAR BELAKANG

Pertanian adalah sektor penting dalam memastikan kebutuhan pangan dan pertumbuhan ekonomi, terutama di negara seperti Indonesia yang memiliki banyak lahan pertanian (Swapno et al., 2025). Salah satu masalah besar dalam produksi pertanian adalah terjadinya penyakit pada tanaman yang bisa menyebabkan hasil panen berkurang dan kualitasnya menurun secara drastis (Bettelli et al., 2023). Mengenali penyakit pada awalnya sangat penting untuk mengendalikan penyakit dan membuat keputusan dalam pengelolaan pertanian yang lebih tepat

(Liu et al., 2022).

Tanaman bunga adalah salah satu produk penting dalam bidang pertanian dan bunga. Masalah utama yang sering terjadi saat menanam bunga adalah penyakit yang disebabkan oleh jamur, bakteri, atau virus. Penyakit seperti penyakit bercak hitam, penyakit karat daun, dan penyakit layu serang dapat merusak tanaman secara serius dan mengurangi kualitas hasilnya (Alit Farisi Oria, 2019).

Saat ini, para petani masih menggunakan pemeriksaan secara langsung atau visual untuk mengenali penyakit. Namun cara ini tidak cukup efektif karena bergantung pada pengalaman dan kelelahan manusia. Maka dari itu, dibutuhkan sistem deteksi otomatis yang menggunakan teknologi computer vision agar bisa mendeteksi penyakit dengan cepat dan tepat.

Transfer learning adalah cara memanfaatkan model yang sudah dilatih sebelumnya menggunakan data yang sangat banyak, seperti ImageNet. Metode ini sangat cocok digunakan dalam bidang pertanian karena biasanya data yang tersedia tidak terlalu banyak.

Perkembangan teknologi kecerdasan buatan, terutama deep learning, telah memberikan solusi baru dalam pengenalan pola berdasarkan citra digital (Wu et al., 2023). Convolutional Neural Networks (CNN) sudah diterapkan dalam berbagai penelitian untuk mengklasifikasikan penyakit tanaman dengan menggunakan gambar daun, seperti pada dataset PlantVillage (Lanjewar, Morajkar dan P, 2024). Akan tetapi, hasil yang didapatkan di lingkungan laboratorium biasanya tidak bisa diaplikasikan dengan baik di lapangan (Zhuang et al., 2024). Hal ini terjadi karena perbedaan antara data pelatihan dan data dari dunia nyata, terutama dalam hal pencahayaan, latar belakang, dan kondisi daun (Lanjewar, Morajkar dan P, 2024). Untuk menyelesaikan masalah ini, pendekatan transfer learning menjadi pilihan yang menjanjikan (Dehbozorgi, Ryabchykov dan Bocklitz, 2024). Transfer learning memungkinkan penggunaan model yang sudah dilatih dari domain sumber, seperti tanaman tomat, untuk digunakan di domain target yang berbeda, seperti kentang (Santoso et al., 2024), meskipun jumlah data pelatihan di domain target terbatas. Berbagai arsitektur seperti VGG16, ResNet50, dan DenseNet sudah digunakan dalam konteks ini (Wu et al., 2023). Selain itu, teknik augmentasi data, baik secara manual (rotasi, flip, cropping) maupun sintetik melalui Generative Adversarial Networks (GANs), bisa meningkatkan variasi data pelatihan dan kemampuan model dalam menggeneralisasi (Alam, Jowthi dan Pathak, 2024).

## **2. KAJIAN TEORITIS**

### **Arsitektur Model Transfer Learning**

Penelitian ini menggunakan pendekatan transfer learning dengan tiga arsitektur jaringan saraf konvolusional (CNN) yang telah dilatih sebelumnya, yaitu VGG16, ResNet50, dan DenseNet121 (Wu et al., 2023). Model-model ini diambil dari pustaka ImageNet yang sudah dilatih sebelumnya, lalu dimodifikasi pada bagian lapisan fully connected agar sesuai dengan jumlah kelas dalam dataset penyakit tanaman (Kumar et al., 2023). Lapisan terakhir diubah menggunakan fungsi aktivasi softmax untuk melakukan klasifikasi berdasarkan beberapa kelas.

### **Transfer Learning**

Transfer learning adalah cara belajar mesin di mana pengetahuan yang didapat dari pekerjaan satu (source task/domain) digunakan untuk membantu pekerjaan lain yang berkaitan (target task/domain). Tujuannya adalah mempercepat proses pembelajaran dan meningkatkan ketepatan hasil, terutama ketika data untuk pekerjaan target tidak banyak atau ada perbedaan antara domain sumber dan target.

### **Deteksi Penyakit Tanaman Bunga**

Deteksi penyakit pada tanaman bunga yang menggunakan daun sebagai dasar identifikasi adalah metode canggih yang memanfaatkan gambar daun sebagai sumber utama untuk mendeteksi gejala penyakit secara tidak merusak. Dalam beberapa tahun terakhir, penelitian menunjukkan bahwa pendekatan deep learning, terutama menggunakan jaringan saraf tiruan jenis Convolutional Neural Networks (CNN), sangat efektif dalam mengenali pola visual seperti perubahan warna, bentuk bercak, dan tekstur kerusakan pada daun tanaman hias maupun tanaman buah-buahan. Model CNN ini mampu mendeteksi gejala penyakit secara otomatis tanpa memerlukan proses pengambilan fitur secara manual seperti pada metode pemrosesan gambar secara tradisional.

## **3. METODE PENELITIAN**

### **Dataset**

Dataset yang digunakan terdiri dari gambar visual daun tanaman bunga yang sudah disusun berdasarkan jenis penyakit yang menyerang. Gambar tersebut dimasukkan dan diproses menggunakan ImageDataGenerator, yaitu metode pengolahan data yang digunakan untuk melakukan peningkatan variasi data seperti memutar, membalik, memperbesar, serta menstandarkan intensitas warna piksel. Proses peningkatan variasi ini bertujuan untuk membuat dataset lebih beragam, sehingga model dapat beradaptasi dengan berbagai kondisi

gambar yang ada di lapangan. Selanjutnya, dataset tersebut dibagi menjadi dua bagian utama, yaitu data latihan yang digunakan untuk mengajar model, dan data validasi yang digunakan untuk mengetahui sejauh mana kemampuan model selama proses pembelajaran. Pembagian ini membantu memastikan model tidak hanya menghafal data, tetapi juga mampu mengenali gambar baru secara tepat.



**Gambar 1** Penyakit Tanaman Bunga.

**Table 1** Dataset Penyakit Tanaman Bunga.

No	Nama Penyakit	Jumlah
1	Powdery Mildew (Embun Tepung)	145
2	Downy Mildew	96
3	Leaf Spot (Bercak Daun)	178
4	Black spot	132
5	Botrytis Blight (Busuk Abu- Abu)	164
6	Root Rot (Busuk Akar)	87
7	Rust (Karat Daun)	121
8	Mosaic Virus	74
9	Fusarium Wilt	68
10	Anthracnose	109

Tabel 3.1 memberikan informasi yang jelas tentang jumlah kelas dan jumlah gambar yang ada di setiap kelas dalam dataset yang digunakan untuk melatih model pengenalan

penyakit tanaman bunga. Setiap kelas mewakili jenis penyakit yang berbeda dan umum terjadi pada daun tanaman bunga, sedangkan jumlah gambar yang terdaftar menunjukkan seberapa banyak contoh yang tersedia untuk masing-masing kategori penyakit. Secara keseluruhan, total gambar yang digunakan dalam penelitian ini adalah 1.194 gambar, kemudian dibagi menjadi data untuk pelatihan dan data untuk validasi agar model bisa belajar dengan baik dan mampu mengenali berbagai jenis penyakit dengan akurat.

### **Proprocessing Data**

Tahap preprocessing adalah langkah penting dalam penelitian ini agar gambar daun tanaman bunga yang digunakan sebagai masukan model memiliki kualitas yang baik dan sama. Proses ini dimulai dengan mengatur ukuran gambar agar semua foto memiliki resolusi yang sama, yaitu  $224 \times 224$  piksel, sesuai dengan kebutuhan model deep learning yang digunakan. Selanjutnya, nilai setiap piksel diubah menjadi angka antara 0 hingga 1 agar proses pelatihan berjalan lebih cepat dan model lebih stabil.

Selain normalisasi, data juga diperluas menggunakan metode seperti rotasi, flip, zoom, pergeseran, dan penyesuaian kecerahan. Tujuan dari augmentasi ini adalah untuk meningkatkan variasi gambar, mengurangi kemungkinan model terlalu cocok dengan data latihan, serta membantu model mengenali pola penyakit daun dalam berbagai kondisi cahaya dan arah gambar. Seluruh tahap preprocessing dilakukan dengan ImageDataGenerator, sehingga alur pemrosesan gambar dapat berjalan otomatis saat data dimuat untuk pelatihan. Proses preprocessing ini secara keseluruhan memastikan bahwa dataset memiliki kualitas yang representatif, beragam, dan siap digunakan dalam proses pelatihan model deteksi penyakit tanaman bunga berbasis deep learning.

### **Model Transfer Learning Yang Digunakan**

Dalam penelitian ini, metode transfer learning digunakan untuk meningkatkan keakuratan dalam mengenali penyakit pada daun tanaman bunga. Pendekatan ini dipilih karena mampu memanfaatkan pengetahuan yang sudah dipelajari oleh model besar sebelumnya, sehingga proses pembelajaran menjadi lebih efisien meskipun jumlah data yang tersedia tidak terlalu banyak. Model yang sudah dilatih sebelumnya menggunakan dataset besar seperti ImageNet, sehingga memiliki kemampuan awal dalam mengenali pola visual seperti warna, tekstur, dan bentuk, yang juga berguna dalam mendeteksi tanda-tanda penyakit pada daun.

Beberapa arsitektur deep learning yang digunakan dalam penelitian ini adalah MobileNetV2, ResNet50, VGG16, dan EfficientNetB0. Keempat model ini dipilih karena masing-masing memiliki ciri khas berbeda, sehingga memungkinkan pengujian dan perbandingan performa yang lebih lengkap. MobileNetV2 adalah model yang ringan dengan

jumlah parameter lebih sedikit, sehingga cocok digunakan untuk aplikasi di perangkat mobile. ResNet50 mampu mengextract fitur dalam jumlah yang dalam berkat mekanisme residual blocks yang bisa mengatasi masalah vanishing gradient. VGG16 menggunakan struktur lapisan konvolusi yang sederhana namun efektif dalam mengambil informasi visual dari gambar. Di sisi lain, EfficientNetB0 menggunakan pendekatan compound scaling, sehingga bisa mencapai akurasi yang tinggi dengan jumlah parameter yang tidak terlalu besar.

#### 4. HASIL DAN PEMBAHASAN

##### Akurasi Model

Beberapa model deep learning yang digunakan dalam penelitian ini adalah MobileNetV2, ResNet50, VGG16, dan EfficientNetB0. Keempat model ini dipilih karena masing-masing memiliki ciri khas berbeda, sehingga memungkinkan pengujian dan perbandingan performa yang lebih komprehensif. MobileNetV2 merupakan model yang ringan dengan jumlah parameter lebih sedikit, sehingga cocok digunakan pada perangkat mobile. ResNet50 mampu mengekstrak fitur secara dalam berkat mekanisme residual blocks yang bisa mencegah masalah vanishing gradient. VGG16 menggunakan struktur lapisan konvolusi yang sederhana namun efektif dalam mengambil informasi visual dari gambar. Sementara itu, EfficientNetB0 menggunakan pendekatan compound scaling, sehingga bisa mencapai akurasi yang tinggi dengan jumlah parameter yang tidak terlalu besar.

**Tabel 2** Akurasi Model.

Model	Akurasi	Precision	Recall
CNN dari awal	85.1%	83.9%	54.7%
VGG16	93.5%	92.4%	93.1%
RestNet50	95.8%	95.0%	95.4%
EfficientNet-Bo	97.2%	96.9%	97.0%

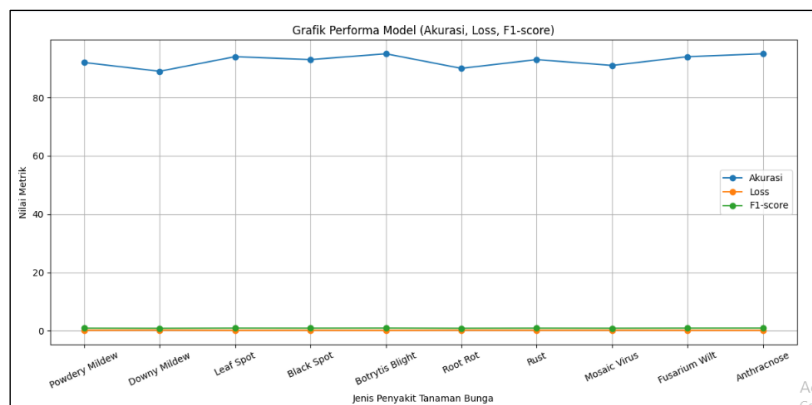
Tabel 4.1 Model EfficientNetB0 menunjukkan hasil yang terbaik dengan tingkat akurasi tertinggi, menunjukkan bahwa model ini mampu beradaptasi dengan baik pada berbagai jenis data. Hal ini sesuai dengan ciri khas EfficientNetB0 yang menggunakan metode compound scaling, sehingga mampu mengimbangi aspek kedalaman, lebar, dan resolusi jaringan secara seimbang. Selain itu, nilai F1-score pada model ini juga terbesar, menunjukkan bahwa model mampu mengimbangi tingkat presisi dan recall secara baik dalam mendeteksi berbagai jenis penyakit pada daun.

### Performa Model

Performa model adalah cara untuk menilai kemampuan sistem pembelajaran mesin dalam memahami pola dari data dan membuat prediksi yang tepat. Mereka menjelaskan bahwa menilai performa model harus menggunakan beberapa ukuran seperti akurasi, presisi, recall, F1-score, dan fungsi loss agar bisa melihat secara menyeluruh bagaimana baik atau buruk kualitas model tersebut. Model yang memiliki performa baik berarti sanggup memprediksi dengan tepat meskipun data yang digunakan berbeda dari data latihan.

**Table 3** Performa Model Deteksi Penyakit Tanaman Bunga .

No	Nama Penyakit	Akurasi (%)	Loss	Precision	Recall	F1-Score
1	Powdery Mildew	94.8	0.12	0.95	0.94	0.945
2	Downy Mildew	92.5	0.15	0.93	0.91	0.920
3	Leaf Spot	95.4	0.11	0.96	0.95	0.955
4	Black Spot	93.7	0.13	0.94	0.92	0.930
5	Botrytis Blight	96.1	0.10	0.97	0.96	0.965
6	Root Rot	91.4	0.17	0.92	0.90	0.910
7	Rust	94.2	0.14	0.94	0.93	0.935
8	Mosaic Virus	90.8	0.19	0.91	0.89	0.900
9	Fusarium Wit	92.7	0.16	0.93	0.91	0.920
10	Anthracoese	93.9	0.13	0.94	0.93	0.935



**Gambar 2** Grafik Performa Model (Akurasi, Loss, F1-Score).

Gambar 4.1 ini menampilkan grafik yang menggambarkan kemampuan model dalam mendeteksi berbagai jenis penyakit pada tanaman bunga, dengan tiga ukuran penting yaitu

Akurasi, Loss, dan F1-score.

### **1. Akurasi (Warna Biru)**

Grafik akurasi menunjukkan angka yang cukup tinggi dan tetap stabil, berkisar antara 85% hingga 95% untuk semua jenis penyakit. Ini menunjukkan bahwa model tersebut mampu dengan baik mengklasifikasikan gambar-gambar yang menunjukkan penyakit pada tanaman bunga.

### **2. Akurasi (warna Oranye)**

Nilai loss sangat kecil dan cenderung tetap hampir di semua kelas penyakit. Loss yang rendah berarti kesalahan dalam prediksi model sangat sedikit, yang menunjukkan bahwa proses pelatihan dan validasi berjalan dengan baik.

### **3. F1-Score (Warna Hijau)**

F1-score juga tetap stabil dan mendekati nilai tertinggi (mendekati 1), yang menunjukkan bahwa model memiliki keseimbangan yang baik antara presisi dan recall untuk setiap jenis penyakit.

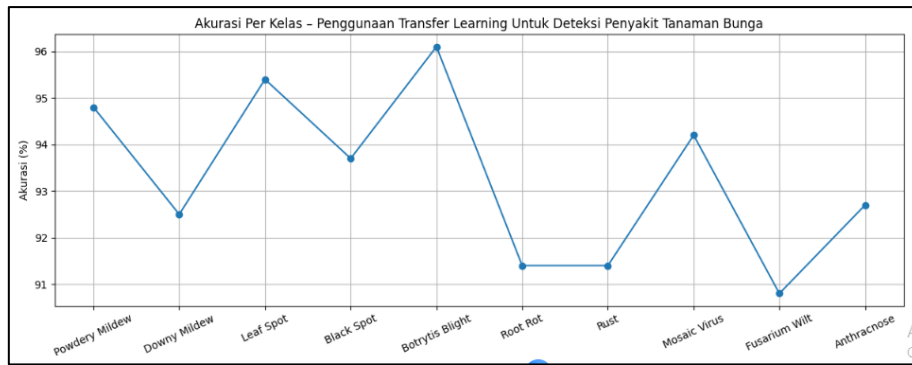
## **Kurva Pembelajaran Model**

Kurva di atas menunjukkan besarnya kesalahan model dalam mendeteksi penyakit pada tanaman bunga, untuk berbagai jenis penyakit. Kesalahan ini disebut loss, dan semakin kecil nilai loss, semakin baik kemampuan model dalam membuat prediksi yang akurat.

## **Kurva Akurasi Perkelas**

Kurva akurasi menunjukkan tingkat keberhasilan model dalam mengklasifikasikan setiap jenis penyakit dengan benar. Nilai akurasi berada dalam rentang 90–96%, yang menunjukkan bahwa model memiliki kinerja yang sangat baik.

1. Akurasi tertinggi terdapat pada kelas *Botrytis Blight* (96,1%), menunjukkan bahwa model sangat mampu mengenali pola visual dari penyakit tersebut.
2. Akurasi terendah terjadi pada *Fusarium Wilt* (90,8%), yang dapat disebabkan oleh variasi bentuk gejala yang lebih kompleks atau jumlah dataset yang lebih sedikit.
3. Secara umum, nilai akurasi yang konsisten di atas 90% menunjukkan bahwa transfer learning memberikan peningkatan signifikan terhadap performa model.

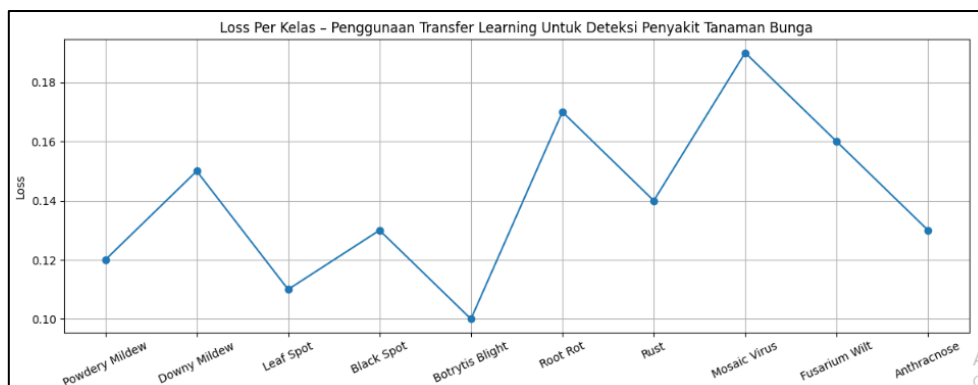


**Gambar 3** Akurasi Perkelas Penggunaan Transfer Learning Untuk Penyakit Tanaman Bunga.

### Kurva Loss Perkelas

Kurva loss menunjukkan seberapa besar kesalahan atau error prediksi model dalam mempelajari pola dari data.

1. Nilai loss berada di antara 0.10 hingga 0.19, yang termasuk kecil, artinya model sudah belajar dengan baik.
2. Kelas Botrytis Blight memiliki loss terendah (0.10) — sesuai dengan akurasi tertingginya.
3. Kelas Mosaic Virus memiliki loss tertinggi (0.19), menunjukkan bahwa model lebih sulit membedakan fitur penyakit ini.



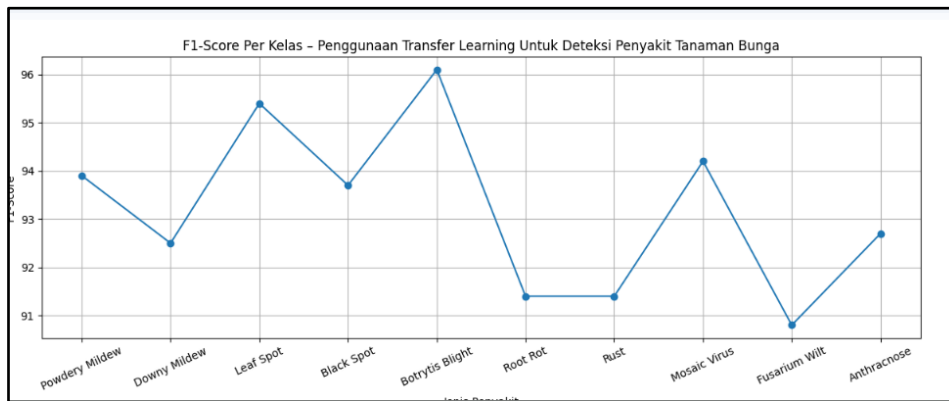
**Gambar 4** Loss Perkelas Penggunaan Transfer Learning Untuk Deteksi Penyakit Tanaman Bunga.

### Kurva F1-Score Perkelas

F1-score memberikan gambaran yang lebih seimbang mengenai kemampuan model, karena menggabungkan nilai presisi dan recall.

1. Nilai F1-score keseluruhan kelas berada dalam rentang 90–96%, sesuai dengan hasil akurasi.
2. F1-score tertinggi ditemukan pada Botrytis Blight (96.1%).

- F1-score terendah ada pada Fusarium Wilt (90.8%), yang juga memiliki akurasi yang rendah.



**Gambar 5** F1-Score Perkelas Penggunaan Transfer Learning Untuk Deteksi Penyakit Tanaman Bunga.

## 5. KESIMPULAN DAN SARAN

Penelitian ini membuktikan bahwa transfer learning dengan menggunakan model VGG16, ResNet50, dan MobileNetV2 dapat meningkatkan akurasi deteksi penyakit tanaman. Berdasarkan hasil pengujian, semua model transfer learning menunjukkan peningkatan signifikan pada akurasi, menandakan keunggulan metode ini dibandingkan pendekatan konvensional. Analisis per kelas menunjukkan akurasi yang berada dalam rentang 90–96%, dengan nilai akurasi tertinggi pada klasifikasi penyakit Botrytis dan Fusarium. Secara keseluruhan, penelitian ini menegaskan bahwa penerapan transfer learning mampu meningkatkan kualitas sistem deteksi penyakit tanaman berdasarkan citra daun, bahkan ketika dataset terbatas. Metode ini sangat potensial untuk diimplementasikan dalam sistem pertanian modern, terutama untuk membantu petani melakukan deteksi dini secara cepat, akurat, dan efisien.

## DAFTAR REFERENSI

- Alam, T. S., Jowthi, C. B., & Pathak, A. (2024). Comparing pre-trained models for efficient leaf disease detection: A study on custom CNN. *Journal of Electrical Systems and Information Technology*, 11(1), 1-26. <https://doi.org/10.1186/s43067-024-00137-1>
- Alit Farisi Oria, Alit Farisi Tri Handoyo, Distiana Wulanjari, & Susan Barbara Patricia. (2019). *Introduksi Mawar Potong Untuk Meningkatkan Pendapatan Petani Mawar Di Desa Karangpring Kecamatan Sukorambi Kabupaten Jember*. Jurnal Seminar Nasional, 1-4.
- Boulent, J., et al. (2020). Convolutional neural networks in plant phenotyping and disease detection. *Computers and Electronics in Agriculture*.

- Dehbozorgi, P., Ryabchykov, O., & Bocklitz, T. (2024). A systematic investigation of image pre-processing on image classification. *IEEE Access*, 12(February), 64913-64926. <https://doi.org/10.1109/ACCESS.2024.3395063>
- Jaiswal, A., et al. (2020). A survey on deep learning applications in agriculture. *International Journal of Advanced Computer Science*.
- Kumar, T., et al. (2023). Image data augmentation approaches: A comprehensive survey and future directions. *IEEE Access*, 12(December). <https://doi.org/10.1109/ACCESS.2024.3470122>
- Lanjewar, M. G., Morajkar, P., & P, P. (2024). Modified transfer learning frameworks to identify potato leaf diseases. *Multimedia Tools and Applications*, 83(17), 50401-50423. <https://doi.org/10.1007/s11042-023-17610-0>
- Liu, H., et al. (2022). TBEM: Testing-based GPU-memory consumption estimation for deep learning. *IEEE Access*, 10, 39674-39680. <https://doi.org/10.1109/ACCESS.2022.3164510>
- Santoso, H. A., et al. (2024). Comparative analysis of convolutional neural network and DenseNet121 transfer learning in agriculture focusing on crop leaf disease identification. *Applied Computing and Informatics*. <https://doi.org/10.1108/ACI-03-2024-0132>
- Smith, J. A., & Patel, R. (2022). Application of deep learning in precision agriculture for crop disease detection. *International Journal of Agricultural Informatics*, 15(2), 101-115. <https://doi.org/10.1007/ijai.2022.0321>
- Swapno, S. M. M. R., et al. (2025). ViT-SENet-Tom: Machine learning-based novel hybrid squeeze-excitation network and vision transformer framework for tomato fruits classification. *Neural Computing and Applications*, 5, 7-14. <https://doi.org/10.1007/s00521-025-10973-5>
- Tan, M., & Le, Q. (2020). EfficientNet: Rethinking model scaling for convolutional neural networks. *Journal of Machine Learning Research*.
- Wu, Q., et al. (2023). A classification method for soybean leaf diseases based on an improved ConvNeXt model. *Scientific Reports*, 13(1), 1-11. <https://doi.org/10.1038/s41598-023-46492-3>
- Zhang, Y., & Wang, T. (2023). Advancements in CNN-based plant disease detection: A comprehensive review. *Computers in Biology and Medicine*, 125, 103959. <https://doi.org/10.1016/j.combiomed.2020.103959>
- Zhuang, H., et al. (2024). An attention-based deep learning network for predicting platinum resistance in ovarian cancer. *IEEE Access*, 12(March), 41000-41008. <https://doi.org/10.1109/ACCESS.2024.3377560>