

Klasifikasi Penyakit Tanaman Jeruk Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network Arsitektur EfficientNetV2-S

Christian Richie Wijaya¹, Muhammad Rizky Pribadi²

^{1,2}Program Studi Informatika, Universitas Multi Data Palembang, Palembang, Indonesia

Email : richiewijaya@mhs.mdp.ac.id, rizky@mdp.ac.id

Article Information

Article history

Received 6 April 2026

Revised 27 May 2026

Accepted 4 June 2026

Available 5 June 2026

Keywords

CNN

EfficientNetV2-S

Citrus Leaf Disease

Transfer Learning

Corresponding Author:

Christian Richie Wijaya,
Universitas Multi Data Palembang,
Email :
richiewijaya@mhs.mdp.ac.id

Abstract

The classification of citrus leaf diseases still largely relies on traditional assessment by farmers, which may lead to errors in identifying disease types. Previous studies have widely applied Convolutional Neural Networks (CNNs) for plant disease classification; however, most have utilized first-generation EfficientNet architectures, while the application of EfficientNetV2-S for citrus leaf disease classification remains relatively limited. Furthermore, the implementation of a progressive fine-tuning strategy on the EfficientNetV2-S architecture for this task has not been extensively investigated. Therefore, this study aims to implement the EfficientNetV2-S architecture for citrus leaf disease classification. The dataset used was the Citrus Leaves Prepared dataset from Kaggle, consisting of 596 images categorized into four classes: blackspot, canker, greening, and healthy. The data underwent preprocessing and image augmentation, including flipping, rotation, and zooming, before being divided into training, validation, and testing sets with a ratio of 70:10:20. The model was developed using a transfer learning approach combined with progressive fine-tuning. Experimental results demonstrated that the proposed model achieved a testing accuracy of 93.33% under the 100-epoch training scenario. With this level of accuracy, the model shows strong potential for implementation as an early detection system for citrus leaf diseases, assisting farmers in making timely and appropriate decisions to prevent crop failure.

Keywords : *Citrus Leaf Disease, CNN, EfficientNetV2-S, Transfer Learning*

Abstrak

Proses klasifikasi penyakit daun jeruk yang masih bergantung secara tradisional oleh petani berpotensi memicu keliruan dalam penentuan jenis penyakit. Berbagai penelitian sebelumnya telah menerapkan Convolutional Neural Network (CNN) untuk klasifikasi penyakit tanaman, namun sebagian besar masih menggunakan arsitektur EfficientNet generasi pertama, sedangkan pemanfaatan EfficientNetV2-S pada klasifikasi penyakit daun jeruk masih relatif terbatas. Selain itu, penerapan strategi progressive fine-tuning pada arsitektur EfficientNetV2-S untuk tugas tersebut juga belum banyak dikaji. Oleh karena itu, penelitian ini bertujuan mengimplementasikan arsitektur EfficientNetV2-S untuk mengklasifikasikan penyakit daun jeruk. Dataset yang digunakan adalah Citrus Leaves Prepared dari Kaggle yang terdiri atas 596 citra dalam empat kelas, yaitu blackspot, canker, greening, dan healthy. Data diproses melalui tahap prapemrosesan dan augmentasi citra berupa flipping, rotasi, dan zooming, kemudian dibagi menjadi data training, validation, dan testing dengan rasio 70:10:20. Model dikembangkan menggunakan pendekatan transfer learning dan progressive fine-tuning. Hasil pengujian menunjukkan model mampu mencapai testing accuracy sebesar 93.33% pada skenario epoch 100. Dengan capaian akurasi tersebut, model ini berpotensi besar untuk diimplementasikan sebagai sistem deteksi dini penyakit daun jeruk guna membantu petani mengambil tindakan secara cepat dan tepat untuk mencegah kegagalan panen.

Kata Kunci : *CNN, EfficientNetV2-S, Penyakit Daun Jeruk, Transfer Learning*

Copyright©2026 Christian Richie Wijaya, Muhammad Rizky Pribadi
This is an open access article under the [CC-BY-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/) license.

1. Pendahuluan

Tumbuhan jeruk merupakan tumbuhan berbunga berasal dari anggota *Citrus* dan dari suku *Rutaceae* (Siagian et al., 2022). Jeruk termasuk komoditas buah yang banyak diminati masyarakat untuk dikonsumsi sehari-hari. Data menunjukkan bahwa kebutuhan jeruk di tingkat rumah tangga mengalami pertumbuhan sebesar 0,52%/kg/kapita/tahun selama periode tahun 2015 hingga 2019 (Wicaksono & Endarto, 2019). Jeruk mengandung banyak vitamin dan mineral sehingga sangat bagus untuk dikonsumsi bagi tubuh. Selain itu, jeruk juga bermanfaat bagi kulit dan rambut karena mengandung vitamin C yang kaya akan antioksidan.

Di kawasan ASEAN, Indonesia tercatat sebagai pengimpor jeruk terbesar setelah Malaysia. Namun, jumlah impor buah jeruk Indonesia mengalami penurunan sebesar 2.212 ton, salah satunya disebabkan oleh Gulma (Nugroho et al., 2023). Selain itu, praktik budidaya jeruk dalam pertanian modern yang masih mengandalkan penggunaan pupuk berlebihan kini menjadi perhatian utama karena dampaknya terhadap lingkungan dan ekosistem. Di sisi lain, kendala signifikan dalam budidaya jeruk adalah rentan terhadap berbagai gangguan penyakit, terutama yang menyerang bagian daun tanaman, salah satunya adalah *Citrus Vein Phloem Degeneration* (CVPD) atau yang dikenal dengan penyakit *greening*. Oleh karena itu, identifikasi penyakit daun jeruk sejak tahap awal menjadi langkah krusial agar kerugian hasil panen dapat ditekan dan kondisi tanaman tetap terjaga dalam jangka waktu lama (Soleha et al., 2025).

Secara umum, mayoritas petani masih mengandalkan pengamatan secara langsung untuk mengenali penyakit tanaman jeruk. Namun, cara konvensional ini cenderung bergantung pada kemampuan dan pengalaman masing-masing individu, sehingga berpotensi menghasilkan kesalahan dalam mengidentifikasi jenis penyakit yang menyerang tanaman (Acarya et al., 2024). Keterbatasan ini dapat menghambat proses pengendalian penyakit, sehingga berpotensi menurunkan produktivitas tanaman jeruk yang dapat menimbulkan kerugian bagi petani. Kondisi ini mengindikasikan urgensi hadirnya solusi berbasis teknologi yang mampu mendukung petani dalam mengidentifikasi penyakit pada daun tanaman secara efisien dan tepat sasaran. Oleh karena itu, pemanfaatan teknologi *Artificial Intelligence*, khususnya *machine learning* menjadi solusi yang menjanjikan untuk mendukung deteksi penyakit tanaman secara objektif, konsisten, dan akurat (Rizal et al., 2025).

Salah satu tantangan utama dalam klasifikasi penyakit daun jeruk berbasis citra adalah adanya kemiripan karakteristik visual antar kelas penyakit. Keberadaan gejala visual yang saling menyerupai menyebabkan proses pembedaan antara daun sehat, daun terinfeksi, maupun antarjenis penyakit daun menjadi lebih kompleks sehingga masih menjadi tantangan dalam identifikasi penyakit tanaman berbasis citra (Min et al., 2024). Selain itu, berbagai penelitian menunjukkan bahwa sistem klasifikasi penyakit tanaman memanfaatkan beragam fitur visual, seperti warna, bentuk, dan tekstur untuk

membedakan setiap kelas penyakit (Ramanjot et al., 2023). Kompleksitas karakteristik visual tersebut menjadikan identifikasi penyakit tanaman sebagai salah satu permasalahan yang menantang dalam pengembangan sistem *computer vision*.

Meskipun metode *Machine Learning* seperti bisa mencapai akurasi tinggi, metode ini sangat bergantung pada pemilihan parameter serta kurang efektif dalam menangani dataset citra berukuran besar dan kompleks (Wardani & Leonardi, 2023). Di sisi lain, muncul pendekatan baru yaitu *Deep Learning* merupakan perluasan dari *Machine Learning* yang muncul seiring meningkatnya kebutuhan akan pemrosesan data berskala besar dan kompleks (Rijal et al., 2024). Salah satu model di dalamnya yaitu *Convolutional Neural Network* (CNN) yang mampu menangkap pola data yang lebih kompleks sehingga menghasilkan keunggulan akurasi yang signifikan jika disandingkan dengan metode *Machine Learning* (Wardani & Leonardi, 2023). Namun, performa CNN juga sangat dipengaruhi oleh jumlah dan keberagaman citra pada *dataset* yang digunakan (Chowdhury et al., 2023), sehingga keterbatasan *dataset* dapat mempengaruhi kemampuan generalisasi model. Untuk mengatasi hal tersebut, penerapan teknik augmentasi data dapat digunakan untuk meningkatkan variasi data serta mengurangi resiko *overfitting* (Irvai & Mahdalena, 2025).

Studi ini mencoba mengimplementasikan pendekatan *Convolutional Neural Network* (CNN) dengan memanfaatkan arsitektur *EfficientNetV2-S* sebagai model utama dalam proses klasifikasi penyakit tanaman jeruk berbasis citra daun. *Dataset* yang digunakan berasal dari Kaggle yaitu *Citrus Leaves Prepared* yang memuat sebanyak 596 citra dan terbagi ke dalam empat kelas. Data secara keseluruhan lalu dipecah menjadi tiga kelompok, meliputi data pelatihan, data validasi, dan data uji, dengan rasio masing-masing sebesar 70%, 10%, dan 20%. Guna memperkaya variasi data latih, diterapkan teknik augmentasi data secara *real-time* yang mencakup tiga transformasi utama, meliputi *flipping*, rotasi, dan *zooming*. Di samping itu, penelitian ini turut mengintegrasikan strategi *transfer learning* berbasis model *EfficientNetV2-S* yang sebelumnya telah dilatih pada *dataset ImageNet*, yang kemudian dilanjutkan dengan proses *progressive fine-tuning* melalui pembukaan sebagian *layer* akhir model untuk meningkatkan kemampuan adaptasi terhadap karakteristik citra penyakit daun jeruk.

Kebaruan utama yang ditawarkan dalam penelitian ini adalah pengimplementasian arsitektur *EfficientNetV2-S* melalui strategi *transfer learning* dan *progressive fine-tuning* untuk mengklasifikasikan penyakit daun jeruk berbasis citra digital. Tak hanya itu, penelitian ini diharapkan mampu membuka cakrawala baru dalam pengembangan sistem klasifikasi penyakit tanaman yang memanfaatkan teknologi kecerdasan buatan, sehingga mampu mendukung petani dalam mengidentifikasi penyakit tanaman dengan lebih efisien dan presisi.

2. Kajian Terdahulu

Penelitian terkait klasifikasi penyakit tanaman jeruk menggunakan *machine learning* telah banyak dilakukan sebelumnya. Penelitian oleh (Hilmi et al., 2024) menunjukkan bahwa metode *K-Nearest Neighbor* mampu mengidentifikasi penyakit daun jeruk dengan sangat baik. Akurasi tertinggi mencapai 98,5% pada skenario pembagian dengan proporsi *training* dan *validation*, yakni 90:10 dengan nilai $K = 2$. Penelitian oleh (Solihin et al., 2026) melakukan perbandingan antara algoritma *Decision Tree* dan *Logistic Regression* dalam upaya mengklasifikasikan penyakit daun multispesies dengan *dataset* berasal dari PlantVillage, dengan menggabungkan fitur berbasis warna dan tekstur sebagai representasi data. Dari hasil pengujian, algoritma *Logistic Regression* mencatatkan performa terbaik dengan akurasi 79,89%, sementara *Decision Tree* hanya mampu meraih akurasi 76,81%, sehingga dinilai lebih andal dalam menangani klasifikasi penyakit daun tanama dengan berbagai kelas.

Selain metode *machine learning*, pendekatan *deep learning* juga mulai banyak digunakan dalam klasifikasi penyakit tanaman jeruk, khususnya melalui arsitektur *Convolutional Neural Network* (CNN). Misalnya, penelitian oleh (Swasono et al., 2023) yang mengimplementasikan CNN berbasis arsitektur *AlexNet* dengan menerapkan augmentasi citra berupa *resize*, *rotation*, *rescale*, dan *horizontal flip*. Penelitian tersebut menggunakan beberapa skenario pembagian data, di mana performa terbaik dicapai pada komposisi 90% data latih dan 10% data validasi, dengan nilai akurasi 94,34%, *precision* 93%, *recall* 94%, serta *F1-score* sebesar 95%.

Kajian yang digagas oleh (Riswandi et al., 2021) menggunakan arsitektur *MobileNet* dalam mengklasifikasikan penyakit daun jeruk. *Dataset* yang digunakan berjumlah 90 citra dibagi dengan skema 80% *training* dan 20% *testing*. Dari proses pengujian, diperoleh akurasi pelatihan model sebesar 98%, namun akurasi validasi menurun hingga sekitar 70%. Penurunan performa ini disebabkan oleh jumlah *dataset* yang terlalu kecil, sehingga kemampuan generalisasi model pada data uji masih belum optimal.

Studi yang dilakukan oleh (Rukuna et al., 2025) menggunakan *EfficientNet-B5* dalam mengklasifikasikan penyakit daun jeruk. *Dataset* didistribusikan dengan komposisi 80% *training*, 10% *validation*, dan 10% *testing*, dengan total pelatihan sebanyak 100 *epoch*. Dalam mengatasi ketidakseimbangan distribusi kelas pada *dataset*, studi tersebut mengombinasikan teknik augmentasi data *fusion* dan *SMOTE*. Hasil evaluasi menunjukkan bahwa model mampu memperoleh akurasi validasi sebesar 99,22%. Selain itu, *EfficientNet-B5* menunjukkan performa paling tinggi dibandingkan *DenseNet-169* dan *ResNet-50* dalam klasifikasi penyakit daun jeruk.

Selanjutnya, studi yang dilakukan oleh (Acarya et al., 2024) mengimplementasikan arsitektur *EfficientNetB3* sebagai model utama dalam proses klasifikasi penyakit daun jeruk siam. *Dataset* yang digunakan berjumlah 480 citra yang

diperoleh langsung dari kebun jeruk, yang kemudian dibagi menggunakan skema 80% *training* dan 20% *testing*, kemudian dilakukan variasi pengujian menggunakan *epoch* 5 dan 10, serta dua pilihan *optimizer* yakni Adam dan RMSprop. Model *EfficientNetB3* digunakan menggunakan bobot *pre-trained* dari *dataset ImageNet* melalui strategi *transfer learning*, kemudian diperkuat dengan penambahan sejumlah lapisan, meliputi *Batch Normalization*, *Dense* dengan regularisasi L1 dan L2, aktivasi *ReLU*, dan *Dropout* untuk mencegah *overfitting*. Hasil terbaik diperoleh pada *epoch* 10 dengan *optimizer* Adam yang menghasilkan Akurasi *Testing* sebesar 98%, sehingga menunjukkan bahwa *EfficientNetB3* berbasis *transfer learning* memiliki kemampuan klasifikasi yang sangat baik dalam mendeteksi penyakit daun jeruk siam.

Studi yang digagas oleh (Fadhilatuzzahro et al., 2025) mengimplementasikan arsitektur *EfficientNet-B0* untuk klasifikasi penyakit buah jeruk. Data dibagi ke dalam tiga skenario proporsi *training* dan *validation*, yakni 90:10, 80:20, dan 70:30, sementara data uji dipisahkan sejak tahap awal sebelum proses pelatihan berlangsung. Model dilatih dengan memanfaatkan *optimizer* Adam dengan *categorical crossentropy* sebagai fungsi *loss*, yang dujalakan selama 50 *epoch*. Pada strategi *fine tuning*, seluruh *layer* dasar *EfficientNet-B0* dibekukan, kemudian lima *layer* terakhir dibuka untuk disesuaikan dengan karakteristik dataset. Hasil terbaik diperoleh pada pembagian data 80:20, di mana model dengan *fine tuning* mencapai akurasi 98,46%, meningkat dibandingkan model tanpa *fine tuning* yang memperoleh akurasi 96,83%.

EfficientNet menunjukkan keunggulan dari sisi efisiensi dan akurasi komputasi daripada arsitektur CNN lainnya. Namun, *EfficientNet* masih memiliki kelemahan yaitu pada proses pelatihan yang kurang efisien. Sehingga, dikembangkanlah *EfficientNetV2* dengan pendekatan *training-aware neural architecture search* (NAS) dan *Fused-MBConv* untuk mengatasi kecepatan proses pelatihan tersebut (Tan & Le, 2021). *EfficientNetV2* hadir dalam beberapa varian salah satunya *EfficientNetV2-S* yang merupakan varian dengan ukuran lebih kecil yang dioptimalkan kecepatan pelatihan dan efisiensi komputasi pada data yang lebih kecil (Gencer, 2025).

Dalam studi (Huang et al., 2023), mengusulkan sistem diagnosis penyakit buah jeruk dengan mengintegrasikan modul *Inception* dan *EfficientNetV2-S*. *Dataset* yang dimanfaatkan mencakup 800 citra buah jeruk yang selanjutnya diperbesar menjadi 2.000 citra melalui teknik augmentasi seperti *flipping* dan rotasi guna meningkatkan variasi data. Keseluruhan data kemudian dibagi dengan rasio pembagian 70% sebagai subset latih, 10% sebagai subset validasi, serta 20% sebagai subset pengujian. Pengujian yang dijalankan membuktikan bahwa model memapu meraih akurasi klasifikasi di atas 95% dan mendekati 88% pada akurasi segmentasi tingkat keparahan penyakit. Secara keseluruhan, metode yang diusulkan terbukti efektif dalam mendeteksi sekaligus menilai tingkat keparahan penyakit pada buah jeruk secara otomatis dan efisien.

Berdasarkan kajian terhadap penelitian-penelitian di atas, dapat diidentifikasi beberapa pola penting. Dari sisi metode, pendekatan *machine learning* seperti KNN, *Decision Tree*, dan *Logistic Regression* mampu menghasilkan akurasi yang kompetitif, namun sangat bergantung pada rekayasa fitur manual dan kurang mampu menangani kompleksitas data citra secara langsung (Hilmi et al., 2024; Solihin et al., 2026). Sementara itu, metode berbasis CNN terbukti lebih unggul dalam ekstraksi fitur otomatis dari citra. Dari sisi arsitektur, varian *EfficientNet* secara konsisten menunjukkan performa lebih tinggi dibandingkan *AlexNet* dan *MobileNet*. *EfficientNet-B5* mampu mencapai akurasi validasi 99,22% (Rukuna et al., 2025), *EfficientNetB3* mencapai akurasi testing 98% (Acarya et al., 2024), dan *EfficientNet-B0* mencapai akurasi 98,46% (Fadhilatuzzahro et al., 2025), jauh melampaui *AlexNet* yang hanya memperoleh akurasi 94,34% (Swasono et al., 2023) dan *MobileNet* yang mengalami penurunan akurasi validasi hingga sekitar 70% akibat keterbatasan dataset (Riswandi et al., 2021). Hal ini menunjukkan bahwa *EfficientNet* unggul dalam menyeimbangkan efisiensi komputasi dan akurasi pada klasifikasi penyakit daun jeruk. Selain itu, penerapan *transfer learning* dan *fine-tuning* terbukti mampu meningkatkan performa klasifikasi secara signifikan, terutama pada kondisi *dataset* yang terbatas (Acarya et al., 2024; Fadhilatuzzahro et al., 2025).

Meskipun demikian, terdapat beberapa kesenjangan yang belum terjawab oleh penelitian-penelitian sebelumnya. Sebagian besar studi masih menggunakan varian *EfficientNet* generasi pertama seperti B0, B3, dan B5 (Rukuna et al., 2025; Acarya et al., 2024; Fadhilatuzzahro et al., 2025), sementara pemanfaatan *EfficientNetV2-S* yang menawarkan efisiensi pelatihan lebih tinggi pada konteks klasifikasi penyakit daun jeruk masih sangat terbatas (Huang et al., 2023). Di sisi lain, strategi *progressive fine-tuning* pada arsitektur *EfficientNetV2-S* untuk klasifikasi penyakit daun jeruk belum ditemukan dalam literatur yang dikaji, sehingga menjadi salah satu kebaruan yang ditawarkan dalam penelitian ini. Selain itu, penelitian yang menggunakan *dataset Citrus Leaves Prepared* dari Kaggle dengan kombinasi strategi augmentasi *real-time* dan *transfer learning* berbasis *EfficientNetV2-S* juga belum ditemukan dalam literatur yang ada. Berdasarkan kesenjangan-kesenjangan tersebut, penelitian ini mengusulkan implementasi *EfficientNetV2-S* dengan strategi *transfer learning* dan *progressive fine-tuning* sebagai pendekatan yang lebih efisien dan adaptif dalam klasifikasi penyakit daun jeruk berbasis citra.

Penyakit Daun Jeruk

Tanaman jeruk (*Citrus sp.*) tergolong dalam komoditas hortikultura yang keberadaannya cukup vital dari sisi ekonomi dan ketahanan pangan (Arezsya et al., 2025). Penurunan hasil produksi buah jeruk umumnya dipicu oleh beragam faktor, di antaranya gangguan hama dan serangan penyakit pada tanaman. Daun jeruk merupakan bagian

tanaman yang mudah terserang oleh jamur, bakteri, maupun virus. Kondisi ini memicu kemunculan beragam jenis penyakit pada daun jeruk, di antaranya *blackspot*, *canker*, dan *greening*. Masing-masing penyakit memiliki karakteristik gejala yang berbeda pada daun, seperti bintik hitam pada *blackspot* (Acarya et al., 2024), bercak yang berkembang menjadi lesi dengan tepi kekuningan hingga kecoklatan pada *canker*, serta daun menguning pada *greening* (Hilmi et al., 2024) sebagaimana diilustrasikan pada Gambar 1.




Gambar 1. Penyakit Daun *Greening* (Dtrilsbeek, 2020).

Augmentasi Data

Augmentasi data adalah strategi pemrosesan yang diterapkan guna memvariasikan tampilan serta posisi suatu citra dari bentuk aslinya. Tujuan dari augmentasi data ini adalah agar model dapat belajar mengenali berbagai variasi gambar yang berbeda, sekaligus dapat dimanfaatkan untuk merekonstruksi data yang ada (Prianka Vedanty et al., 2025). Dengan demikian, augmentasi data hadir sebagai Langkah vital dalam memperkaya variasi data pada *dataset* yang terbatas sehingga mampu meningkatkan kemampuan model.

Convolution Neural Network

Dalam ekosistem *deep learning*, *Convolutional Neural Network* (CNN) dikenal sebagai metode yang banyak dilibatkan dalam pemrosesan citra digital. Keunggulan metode ini terletak pada kemampuannya dalam menangani data visual, mulai dari gambar hingga video, dengan arsitektur yang handal dalam mengurai pola visual untuk mendukung berbagai tugas, di antaranya klasifikasi, deteksi objek, dan segmentasi citra (Budi et al., 2024). Tiga lapisan yang menjadi pondasi Arsitektur CNN meliputi *Convolutional layer*, *pooling layer*, dan *fully connected layer*. *Convolutional layer* berperan dalam menggali informasi yang terkandung dalam citra dengan memanfaatkan kernel sehingga menghasilkan *feature map*. Selanjutnya, *pooling layer* berfungsi untuk mereduksi dimensi data sekaligus mempertahankan fitur penting agar proses komputasi menjadi lebih efisien. Setelah itu, *feature map* dikonversi menjadi representasi satu dimensi melalui proses *flatten* sebelum diteruskan ke *fully connected layer* guna menghasilkan output klasifikasi (Zafar et al., 2022). Arsitektur CNN (Shojaenia et al., 2025) ditunjukkan pada Gambar 2.

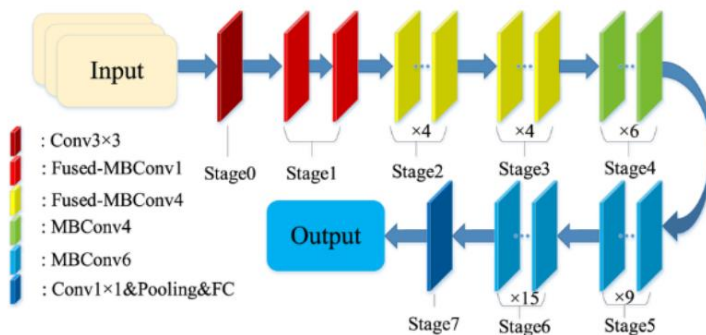


Gambar 2. Arsitektur CNN (Shojacinia et al., 2025).

EfficientNetV2-S

EfficientNetV2 merupakan pengembangan dari arsitektur *EfficientNet* yang diperkenalkan oleh Mingxing Tan dan Quoc V. Le untuk meningkatkan efisiensi komputasi dan kecepatan pelatihan model *Convolutional Neural Network* (CNN). Pengembangan arsitektur ini mempertimbangkan efisiensi pelatihan dengan menerapkan metode *Neural Architecture Search* (NAS) yang disesuaikan dengan proses *training*, serta memanfaatkan blok *Fused-MBConv* pada bagian awal jaringan untuk mempercepat dan mengoptimalkan pelatihan model. Selain itu, *EfficientNetV2* juga tetap mempertahankan penggunaan blok *MBConv* yang dikombinasikan dengan mekanisme *Squeeze-and-Excitation* (SE) untuk meningkatkan kemampuan ekstraksi fitur pada citra. Dibandingkan dengan *EfficientNet* sebelumnya, *EfficientNetV2* memiliki proses pelatihan yang lebih cepat dengan jumlah parameter yang tetap efisien (Tan & Le, 2021).

EfficientNetV2 memiliki beberapa varian model salah satunya, yaitu *EfficientNetV2-S*. *EfficientNetV2-S* merupakan varian dengan ukuran lebih kecil yang dioptimalkan kecepatan pelatihan dan efisiensi komputasi pada data yang lebih kecil (Gencer, 2025). Arsitektur *EfficientNetV2-S* terdiri dari beberapa stage yang diawali dengan operasi konvolusi 3×3 , dilanjutkan dengan blok *Fused-MBConv* pada tahap awal serta blok *MBConv* pada tahap berikutnya untuk proses ekstraksi fitur citra. Pada bagian akhir jaringan digunakan *global average pooling* dan *fully connected layer* untuk menghasilkan output klasifikasi. Gambar 3 menunjukkan arsitektur *EfficientNetV2-S* yang digunakan pada penelitian ini.



Gambar 3. Arsitektur *EfficientNetV2-S* (Huang et al., 2023).

Transfer Learning

Sebagai salah satu strategi *deep learning*, *transfer learning* bekerja dengan mengalihkan pengetahuan model *pre-trained* dari domain sumber ke domain target yang berkaitan. Pendekatan ini memungkinkan model untuk menggunakan kembali fitur-fitur yang telah dipelajari dari *dataset* berukuran masif, seperti *ImageNet*, yang pada akhirnya turut memperkuat daya generalisasi model (Rahman et al., 2025). Selain itu, pendekatan ini memungkinkan model tidak perlu dilatih dari awal dan dapat mencapai performa yang lebih optimal dengan durasi pelatihan yang lebih singkat. *Transfer learning* juga terbukti efektif digunakan pada kondisi *dataset* yang terbatas karena mampu memanfaatkan bobot dan representasi fitur yang telah dipelajari sebelumnya untuk meningkatkan performa klasifikasi (Falakhi et al., 2022).

Dalam penerapannya, *transfer learning* mencakup beberapa pendekatan, di antaranya *classifier*, *feature extraction*, dan *fine-tuning*. Pendekatan *classifier* dilakukan dengan memanfaatkan model yang telah melewati tahap *pre-training* secara langsung untuk tugas yang serupa. *Feature extraction* menggunakan model *pre-trained* sebagai pengekstrak fitur tanpa mengubah bobot utama, sehingga cocok digunakan ketika *dataset* target memiliki kemiripan dengan *dataset* sumber. Sementara itu, *fine-tuning* dilakukan dengan menyesuaikan sejumlah atau seluruh parameter model guna menyelaraskan dengan kondisi spesifik domain target (Muhammad et al., 2023).

Fine-tuning adalah strategi *transfer learning* yang paling banyak digunakan dalam klasifikasi citra. Pada pendekatan ini, beberapa lapisan teratas (*top layers*) dari model *pre-trained* yang sebelumnya dibekukan, dibuka kembali dan dilatih secara bersama-sama dengan lapisan *classifier* yang baru ditambahkan agar model dapat menyesuaikan diri dengan karakteristik domain target (Siddiqi, 2019). *Fine-tuning* umumnya diterapkan dengan *learning rate* yang lebih kecil dibandingkan pelatihan dari awal, dengan tujuan agar bobot dan fitur yang telah dipelajari dari tahap *pre-training* tidak rusak akibat pembaruan yang terlalu agresif (Li et al., 2020). Dengan demikian, *fine-tuning* memungkinkan model untuk mempertahankan representasi fitur yang telah dikuasai sebelumnya sembari menyesuaikan diri pada keunikan *dataset* target.

Confusion Matrix

Confusion matrix digunakan dalam penelitian ini untuk mengevaluasi hasil klasifikasi empat kelas penyakit daun jeruk, yakni *blackspot*, *canker*, *greening*, dan *healthy*, dengan membandingkan prediksi model terhadap label aslinya. Instrumen ini menghasilkan sejumlah metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score* (Heydarian et al., 2022). Tabel 1 menunjukkan *confusion matrix* untuk pengklasifikasi multikelas.

Tabel 1. *Confusion Matrix*.

		<i>Predicted</i>			
		CLASS A	CLASS B	CLASS C	CLASS D
Actual	CLASS A	TP_A	FP_B	FP_C	FP_D
	CLASS B	FN_A	TP_B	FP_C	FP_H
	CLASS C	FN_A	FN_B	TP_C	FP_H
	CLASS D	FN_A	FN_B	FN_C	TP_H

Formula pada persamaan (1) merupakan rumus untuk menghitung *accuracy*.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \tag{1}$$

Adapun rumus untuk mendapatkan nilai *precision*, *recall*, dan *F1-score* ditunjukkan pada persamaan (2), (3), dan (4).

$$Precision = \frac{TP}{TP + FP} \tag{2}$$

$$Recall = \frac{TP}{TP + FN} \tag{3}$$

$$F1 - score = \frac{2 \times recall \times precision}{recall + precision} \tag{4}$$

Keterangan :

TP (*True Positive*): citra positif yang tepat diprediksi positif.

TN (*True Negative*): citra negatif yang tepat diprediksi negatif.

FP (*False Positive*): citra negatif yang keliru diprediksi positif.

FN (*False Negative*): citra positif yang keliru diprediksi negatif.

3. Metodologi Penelitian

Sebagai langkah awal, metode penelitian dirancang secara terstruktur sebelum penelitian dijalankan. Alur metodologi disajikan pada Gambar 4.



Gambar 4. Diagram alur Metodologi Penelitian

Berdasarkan gambar tersebut, setiap tahapan dapat diuraikan sebagai berikut:





1. Studi Literatur

Langkah pertama dimulai dengan mengkaji berbagai sumber literatur ilmiah berupa jurnal, buku, dan penelitian terdahulu yang berkaitan dengan klasifikasi penyakit daun tanaman jeruk berbasis citra daun menggunakan metode *Convolutional Neural Network*.

2. Pengumpulan *Dataset*

Dalam fase ini, dilakukan akuisisi *dataset* berupa citra daun tanaman jeruk yang diperoleh dari *website Kaggle*, yaitu *dataset Citrus Leaves Prepared* (Dtrilsbeek, 2020). *Dataset* tersebut terdiri dari 596 citra yang dikelompokkan menjadi empat kelas, yaitu *blackspot*, *canker*, *greening*, dan *healthy*. Persebaran jumlah data pada tiap kelas dapat dilihat pada Tabel 2.

Tabel 2. Persebaran Jumlah Data Tiap Kelas.

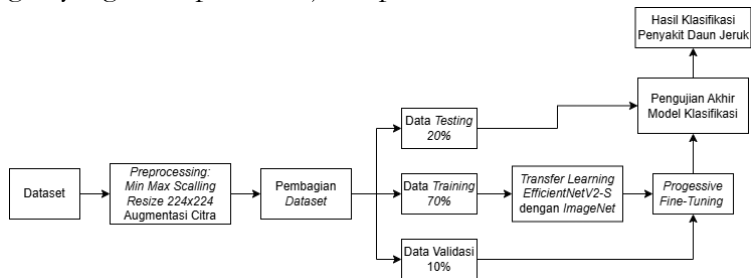
Gambar	Nama Kelas	Jumlah Data
	<i>Blackspot</i>	171
	<i>Canker</i>	163
	<i>Greening</i>	204
	<i>Healthy</i>	58

Tabel 2 menampilkan contoh citra daun pada setiap kelas beserta jumlah data yang digunakan dalam penelitian, yaitu kelas *blackspot* sebanyak 171 citra, *canker* sebanyak 163 citra, *greening* sebanyak 204 citra, dan *healthy* sebanyak 58 citra.

Dataset awalnya telah dipisahkan menjadi data *training* dan *validation*. Namun, untuk kebutuhan penelitian, seluruh data digabungkan kembali dan dilakukan pembagian ulang menjadi data *training*, *validation*, dan *testing* dengan proporsi masing-masing sebesar 70%, 10%, dan 20% yaitu sebanyak 417 citra untuk *training*, 59 citra untuk *validation*, dan 120 citra untuk *testing*. Proses pembagian dilakukan secara acak menggunakan pendekatan *stratified split* agar distribusi kelas tetap merata di setiap subset.

3. Perancangan

Fase ini berfokus pada perancangan arsitektur sistem. Kerangka perancangan yang diterapkan disajikan pada Gambar 5.



Gambar 5. Kerangka Perancangan *EfficientNetV2-S*.


Proses diawali dengan *input* dataset citra daun jeruk yang kemudian melalui tahap *pre-processing* yang meliputi normalisasi pixel menggunakan metode *Min-Max scaling*, *resize* gambar menjadi ukuran 224×224 *pixel*, serta augmentasi citra secara *real-time* selama proses *training* untuk meningkatkan variasi data dan meminimalkan *overfitting*. Rinciannya tersaji pada Tabel 3.

Tabel 3. Rincian Teknik Augmentasi Citra

Teknik Augmentasi	Rincian
<i>Flipping</i>	<i>Horizontal flipping</i>
Rotasi	Rotasi 90° searah & berlawanan jarum jam
<i>Zooming</i>	Range 0,2

Berdasarkan Tabel 3, teknik augmentasi yang digunakan meliputi *horizontal flipping*, rotasi 90° secara *clockwise* dan *counterclockwise*, serta *zooming*

dengan rentang sebesar 0.2. Gambar 6 menunjukkan contoh hasil penerapan masing-masing teknik augmentasi terhadap citra penyakit daun jeruk.



Gambar 6. Hasil Augmentasi Citra Daun Penyakit Jeruk.

Selanjutnya, *dataset* didistribusikan menjadi subset *training*, *validation*, dan *testing* berturut-turut sebesar 70%, 10%, dan 20% menggunakan metode *stratified split*. Data *training* difungsikan guna membangun model, data *validation* dimanfaatkan guna memantau kinerja model saat pelatihan, sementara data *testing* dipakai untuk evaluasi akhir. Pada tahap berikutnya diterapkan pendekatan *transfer learning* dengan menjadikan *EfficientNetV2-S* sebagai model dasar yang telah dilatih pada *dataset ImageNet*. Pada tahap awal, seluruh *layer* pada model dasar dibekukan (*freeze*) dan hanya bagian *classification head* yang dilatih, yang terdiri dari *global average pooling* dan *fully connected layer* dengan fungsi aktivasi *Softmax*.

Selanjutnya dilakukan proses *fine-tuning* secara bertahap dengan membuka (*unfreeze*) beberapa *layer* pada bagian akhir model sekitar 20%, khususnya pada blok *MBConv6* yang terletak pada *stage 5* dan *stage 6*, serta *layer* terakhir pada *stage 7* untuk meningkatkan kemampuan adaptasi terhadap *dataset* penelitian. Pendekatan ini mengacu pada strategi *progressive fine-tuning* yang bertujuan untuk menjaga stabilitas pelatihan serta meningkatkan performa model secara bertahap. Pelatihan model *EfficientNetV2-S* dikonfigurasi menggunakan sejumlah *hyperparameter*, yakni *optimizer* Adam, *learning rate* 0.00001, dan *batch size* sebesar 32. Penentuan kombinasi *hyperparameter* ini didapatkan murni melalui serangkaian uji coba mandiri untuk memastikan grafik *training* berjalan secara stabil, serta mengurangi risiko terjadinya *overfitting* pada data penelitian. Pengujian dilakukan menggunakan empat skenario *epoch*, yaitu 25, 50, 75, dan 100 *epoch* untuk membandingkan performa model pada setiap proses pelatihan. Setelah tahap pelatihan selesai, model terbaik selanjutnya dievaluasi menggunakan data *testing* untuk memperoleh hasil klasifikasi.

4. Implementasi

Pada tahap ini, sistem dikembangkan berbasis *Python* melalui *TensorFlow* dan *Keras* guna membangun model *Convolutional Neural Network* (CNN). Selain itu digunakan *library OpenCV* dan *NumPy* untuk proses *pre-processing* seperti *resize*,

normalisasi *Min-Max scaling*, serta augmentasi citra meliputi *flipping*, *rotasi*, dan *zooming*, sedangkan visualisasi data dilakukan menggunakan *Matplotlib*. *EfficientNetV2-S* dipilih sebagai model utama dengan menerapkan pendekatan *transfer learning*.


5. Pengujian

Pada tahap ini, model *EfficientNetV2-S* yang telah melalui proses pelatihan berbasis *transfer learning* dan *progressive fine-tuning* dievaluasi memanfaatkan data *testing* guna mengukur sejauh mana model mampu mengenali dan mengelompokkan penyakit daun jeruk. Proses pengujian dilakukan pada empat skenario *epoch*, yaitu 25, 50, 75, dan 100 *epoch*, dengan cara membandingkan hasil prediksi model terhadap label actual pada data *testing* untuk menentukan konfigurasi model dengan performa terbaik.

Tahap berikutnya, keluaran pengujian dikaji lebih lanjut melalui *confusion matrix* dan *classification report* guna menilai kualitas model berdasarkan indikator *accuracy*, *precision*, *recall*, dan *F1-score*. Evaluasi ini mengungkapkan kemampuan model dalam membedakan dan mengelompokkan setiap kelas penyakit daun jeruk secara akurat.

4. Hasil dan Pembahasan

Sebagai inti dari studi ini, dilaksanakan serangkaian pengujian terhadap model klasifikasi penyakit daun jeruk yang dibangun menggunakan arsitektur *EfficientNetV2-S* dengan pendekatan *transfer learning* dan *progressive fine-tuning*. Terdapat dua tahapan dalam proses pelatihan, dengan tahapan awal berfokus pada pembekuan (*freeze*) keseluruhan *layer* model menggunakan *transfer learning*, kemudian dilanjutkan dengan *fine-tuning* melalui pembukaan 20% *layer* akhir model. *Dataset* citra terlebih dahulu melalui tahap *pre-processing* dan augmentasi data secara *real-time* untuk memperkaya variasi data serta meminimalkan risiko *overfitting*. Pelatihan model dengan konfigurasi *optimizer* Adam *learning rate* 0.00001 dan *batch size* 32. Pengujian dilakukan menggunakan empat skenario *epoch*, yaitu 25, 50, 75, dan 100 *epoch*. Kualitas model dievaluasi melalui nilai *training accuracy*, *validation accuracy*, dan *testing accuracy*, sedangkan penentuan model terbaik didasarkan pada nilai *testing accuracy* tertinggi dalam klasifikasi penyakit daun jeruk. Hasil pengujian ditunjukkan pada gambar 7.



Gambar 7. Grafik Perbandingan *Training Accuracy* dan *Validation Accuracy* Sebelum dan Sesudah *Fine-Tuning* Setiap Skenario *Epoch*

Pada Gambar 7 ditunjukkan perbandingan *training accuracy* dan *validation accuracy* pada setiap skenario *epoch* sebelum dan sesudah proses *fine-tuning*. Berdasarkan hasil pengujian, proses *fine-tuning* memberikan peningkatan performa model pada seluruh skenario *epoch*. Hal ini menunjukkan bahwa pembukaan sebagian *layer* pada blok akhir *EfficientNetV2-S* mampu meningkatkan kemampuan model dalam mempelajari karakteristik citra penyakit daun jeruk secara lebih spesifik.

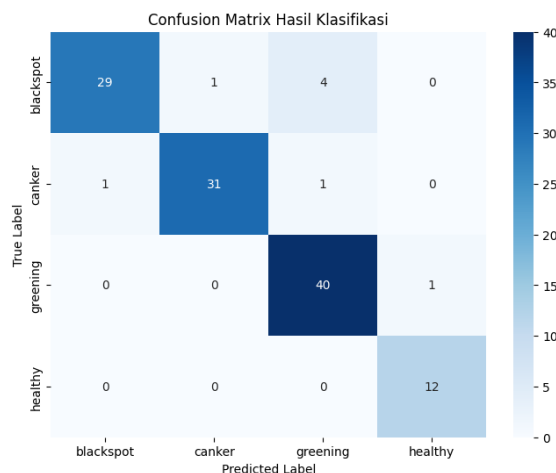
Pada skenario *epoch* 25, model memperoleh *training accuracy* sebesar 84.41%, *validation accuracy* sebesar 91.53%, dan *testing accuracy* sebesar 89.17%. Hasil tersebut mengindikasikan bahwa model telah mampu menjalankan proses klasifikasi dengan cukup baik meskipun jumlah *epoch* relatif sedikit. Pada skenario *epoch* 50, performa model meningkat dengan *training accuracy* sebesar 95.92%, *validation accuracy* sebesar 93.22%, dan *testing accuracy* sebesar 90.83%. Peningkatan ini menunjukkan bahwa penambahan jumlah *epoch* membantu model dalam mempelajari pola citra secara lebih optimal. Selanjutnya pada skenario *epoch* 75, model memperoleh *training accuracy* sebesar 98.56%, *validation accuracy* sebesar 94.92%, dan *testing accuracy* sebesar 92.50%. Hasil ini mengindikasikan bahwa daya generalisasi model semakin meningkat pada data validasi maupun data pengujian. Sementara itu, skenario *epoch* 100 menghasilkan *testing accuracy* tertinggi sebesar 93.33%, dengan *training accuracy* sebesar 84.89% dan *validation accuracy* sebesar 91.53%. Berdasarkan hasil tersebut, model pada skenario *epoch* 100 dipilih sebagai model terbaik karena mampu menghasilkan performa pengujian tertinggi pada data testing. Tingginya nilai *testing accuracy* menunjukkan bahwa model sanggup mengenali pola pada data baru yang asing bagi model.

Selanjutnya dilakukan pengujian model menggunakan data *testing* untuk mengetahui kemampuan klasifikasi tiap kelas penyakit daun jeruk. Kualitas model dikaji lebih lanjut menggunakan *classification report* yang memuat indikator *precision*, *recall*, dan *f1-score* untuk tiap kelas. Tabel 4 menyajikan hasil *classification report* secara lengkap.

Tabel 4. Hasil *Classification Report*

	Precision	Recall	F1-Score	Support
Blackspot	0,97	0,85	0,91	34
Canker	0,97	0,94	0,95	33
Greening	0,89	0,98	0,93	41
Healthy	0,92	1,00	0,96	12
Accuracy				120
Macro Avg	0,94	0,94	0,94	120
Weighted Avg	0,94	0,93	0,93	120

Pada Tabel 4 ditunjukkan hasil *classification report* model *EfficientNetV2-S* pada skenario *epoch* terbaik, yaitu *epoch* 100. Hasil evaluasi mengindikasikan bahwa model terbukti andal dalam mengklasifikasikan penyakit daun jeruk ditinjau dari *precision*, *recall*, dan *f1-score* pada tiap kelas. Kelas *canker* memperoleh nilai *precision* 0.97, *recall* 0.94, dan *f1-score* 0.95, membuktikan model mampu mengidentifikasi karakteristik penyakit *canker* secara konsisten. Pada kelas *greening*, model memperoleh *recall* 0.98 dengan *f1-score* 0.93, yang mengindikasikan bahwa sebagian besar citra *greening* berhasil diidentifikasi dengan benar oleh model. Sementara itu, kelas *healthy* memperoleh *recall* tertinggi yakni 1.00 dengan *f1-score* 0.96, yang membuktikan seluruh citra *healthy* teridentifikasi sempurna tanpa kekeliruan. Untuk kelas *blackspot*, model memperoleh *precision* 0.97 dan *recall* 0.85, yang menunjukkan masih terdapat beberapa citra *blackspot* tergolongkan pada kelas yang tidak tepat. Meskipun demikian, nilai *f1-score* sebesar 0.91 membuktikan bahwa kinerja klasifikasi pada kelas tersebut masih cukup mumpuni. Secara umum, model menghasilkan *accuracy* sebesar 93.33%, yang menunjukkan bahwa penerapan *transfer learning* dan *progressive fine-tuning* pada arsitektur *EfficientNetV2-S* mampu memberikan performa klasifikasi yang efektif pada citra penyakit daun jeruk. Selain itu, visualisasi berupa *confusion matrix* hasil klasifikasi model diilustrasikan pada Gambar 8.

Gambar 8. Hasil *Confusion Matrix*

Confusion matrix pada Gambar 8 mengindikasikan bahwa sebagian besar data berhasil diprediksi secara tepat pada masing-masing kelas. Pada kelas *blackspot*, sebanyak 29 citra berhasil diklasifikasikan dengan benar, sedangkan beberapa citra lainnya keliru diprediksi sebagai *canker* dan *greening*. Hal ini mengindikasikan bahwa terdapat kesamaan visual antar penyakit membuat model sulit membedakan beberapa sampel tertentu. Pada kelas *canker*, sebanyak 31 dari 33 citra berhasil diprediksi dengan benar dan hanya sebagian kecil data yang keliru diklasifikasikan ke kelas lain. Sementara itu, kelas *greening* berhasil memprediksi 40 citra secara akurat dan hanya 1 citra yang salah diklasifikasikan sebagai *healthy*. Kelas *healthy* memperoleh hasil klasifikasi sempurna dengan seluruh citra dikenali model tanpa kekeliruan. Pola kesalahan klasifikasi yang relatif kecil menunjukkan bahwa fitur yang dipelajari model melalui proses *transfer learning* dan *fine-tuning* mampu membedakan karakteristik masing-masing penyakit daun jeruk dengan cukup baik.

Dari sisi metodologi, hasil penelitian ini menunjukkan bahwa penerapan *transfer learning* menggunakan arsitektur *EfficientNetV2-S* yang dikombinasikan dengan *progressive fine-tuning* efektif dalam meningkatkan performa klasifikasi citra penyakit daun jeruk. Proses *fine-tuning* dengan membuka 20% *layer* terakhir memungkinkan model untuk menyesuaikan fitur yang telah dipelajari dari dataset *ImageNet* terhadap karakteristik spesifik citra daun jeruk. *Optimizer* Adam dengan *learning rate* sebesar 0.00001, *batch size* 32, serta augmentasi citra secara *real-time* turut membantu meningkatkan kemampuan generalisasi model sekaligus meminimalkan risiko *overfitting* selama proses pelatihan. Berdasarkan perbandingan beberapa skenario *epoch*, model pada *epoch* 100 menghasilkan *testing accuracy* tertinggi sebesar 93.33%, sehingga dipilih sebagai model terbaik pada penelitian ini. Meskipun demikian, kekeliruan klasifikasi masih muncul pada kelas yang memiliki karakteristik visual yang mirip, seperti *blackspot* dan *greening*. Hal tersebut menunjukkan bahwa variasi pola bercak, warna daun, dan kondisi pencahayaan dapat memengaruhi kemampuan model dalam melakukan klasifikasi secara konsisten.

Meskipun hasil yang diperoleh cukup menjanjikan, penelitian ini memiliki beberapa keterbatasan yang perlu diakui. *Dataset* yang digunakan relatif kecil dengan variasi kondisi citra yang terbatas, sehingga kemampuan generalisasi model ketika dihadapkan pada kondisi lapangan yang lebih beragam seperti perbedaan pencahayaan, kualitas kamera, dan latar belakang citra belum dapat dipastikan sepenuhnya. Di samping itu, penelitian ini hanya menguji satu arsitektur model sehingga perbandingan performa secara langsung dengan arsitektur lain pada *dataset* yang sama belum dilakukan. Terlepas dari keterbatasan tersebut, temuan penelitian ini memberikan bukti empiris bahwa kombinasi *transfer learning* dan *progressive fine-tuning* pada *EfficientNetV2-S* mampu menghasilkan klasifikasi yang kompetitif meski dengan dataset terbatas, sekaligus memperkuat argumen bahwa pembukaan layer secara bertahap lebih efektif dalam menyesuaikan representasi fitur terhadap karakteristik domain yang spesifik.

Model yang dikembangkan dalam penelitian ini berpotensi diintegrasikan ke dalam sistem berbasis *mobile* maupun *web* yang dapat dimanfaatkan langsung oleh petani di lapangan. Dengan akurasi sebesar 93.33%, model ini dapat menjadi alat bantu identifikasi penyakit daun jeruk secara cepat dan objektif tanpa memerlukan keahlian khusus, sehingga mendukung deteksi dini dan menekan potensi kerugian hasil panen. Dalam pengembangan berikutnya, penambahan jumlah *dataset* dengan variasi kondisi citra yang lebih beragam dari lingkungan nyata diharapkan dapat memperkuat kemampuan generalisasi model. Selain itu, eksplorasi varian arsitektur lain seperti *EfficientNetV2-M* atau *EfficientNetV2-L* menarik untuk dikaji.

5. Kesimpulan

Penerapan *EfficientNetV2-S* melalui *transfer learning* dan *progressive fine-tuning* berhasil mengklasifikasikan penyakit daun jeruk, bahkan pada kondisi *dataset* yang relatif terbatas. Berdasarkan hasil pengujian, skenario *epoch* 100 menghasilkan performa terbaik dengan *testing accuracy* sebesar 93.33%. Hal ini mengindikasikan bahwa pembukaan *layer* secara bertahap mampu meningkatkan kemampuan adaptasi model terhadap karakteristik visual domain spesifik, sehingga menghasilkan klasifikasi yang kompetitif tanpa memerlukan dataset berskala besar. Tingginya nilai akurasi ini menunjukkan adanya potensi pada penelitian ini untuk dijadikan sebagai solusi deteksi dini penyakit daun jeruk di lapangan, sehingga petani dapat mengambil tindakan pengendalian secara cepat dan tepat untuk mencegah gagal panen.

Berdasarkan hasil pengujian pada tiap jenis penyakit, model terbukti menunjukkan keberhasilan identifikasi sempurna pada kelas *healthy* dengan nilai *recall* mencapai 1.00 tanpa ada kesalahan prediksi. Meskipun demikian, ditemukan kendala minor pada kelas *blackspot* karena model beberapa kali keliru mengklasifikasikannya ke kelas lain. Kondisi ini dipicu oleh adanya kemiripan karakteristik visual, pola bercak, dan warna antara kelas *blackspot* dengan kelas *canker* maupun *greening*.

Meski hasil model cukup efektif, terdapat beberapa keterbatasan yang perlu dicermati. Faktor pembatas tersebut terletak pada jumlah *dataset* yang relatif kecil serta variasi kondisi citra yang digunakan. *Dataset* yang terbatas dapat memengaruhi kemampuan generalisasi model ketika dihadapkan pada kondisi lingkungan yang berbeda, seperti perubahan pencahayaan, kualitas kamera, maupun latar belakang citra.

Untuk mengatasi keterbatasan tersebut, pada penelitian selanjutnya dapat dikembangkan melalui beberapa langkah. Pertama, jumlah *dataset* dapat diperbanyak dengan kondisi citra yang lebih beragam guna memperkuat kemampuan generalisasi model. Langkah pengembangan berikutnya yang sangat potensial adalah mengintegrasikan sistem klasifikasi berbasis *EfficientNetV2-S* ini ke dalam aplikasi perangkat mobile. Dengan demikian, teknologi kecerdasan buatan ini dapat

diimplementasikan secara praktis dan nyata oleh para petani langsung di area perkebunan jeruk untuk mendukung proses deteksi dini secara *real-time*.

6. Pernyataan Penulis

Penulis menyatakan bahwa tidak ada konflik kepentingan terkait publikasi artikel ini. Penulis menyatakan bahwa data dan makalah bebas dari plagiarisme serta penulis bertanggung jawab secara penuh atas keaslian artikel.

Bibliografi

- Acarya, B. S., Muhaimin, A., & Hindrayani, K. M. (2024). Identifikasi Penyakit Daun Jeruk Siam Menggunakan Convolutional Neural Network (CNN) dengan Arsitektur EfficientNet. *G-Tech: Jurnal Teknologi Terapan*, 8(2), 1040–1048. <https://doi.org/10.33379/gtech.v8i2.4120>
- Arezsya, M. B., Risnawati, R., & Shafie, M. (2025). Karakteristik Tanaman Jeruk (*Citrus* sp.) di Plot Biospropeksi Spesies Jeruk Terpilih. *Agrotekma: Jurnal Agroteknologi Dan Ilmu Pertanian*, 9(2), 38–50.
- Budi, E. S., Chan, A. N., Alda, P. P., & Idris, M. A. F. (2024). Optimasi Model Machine Learning untuk Klasifikasi dan Prediksi Citra Menggunakan Algoritma Convolution Neural Network. *RESOLUSI: Rekayasa Teknik Informatika Dan Informasi*, 4(5), 502–509.
- Chowdhury, M. J. U., Mou, Z. I., Afrin, R., & Kibria, S. (2023). Plant Leaf Disease Detection and Classification Using Deep Learning: A Review and A Proposed System on Bangladesh's Perspective. *International Journal of Science and Business*, 28(1), 193–204.
- Dtrilsbeek. (2020). *Citrus Leaves Prepared*. Dtrilsbeek. <https://www.kaggle.com/dtrilsbeek/citrus-leaves-prepared/data>
- Fadhilatuzzahro, M., Fazrin, A., Arishandy, Z. I., Sukoco, T. A., & Maulana, H. (2025). Optimalisasi Model CNN EfficientNet-B0 dengan Fine Tuning untuk Klasifikasi Penyakit Buah Jeruk. *Jurnal Ilmiah Teknologi Informasi Dan Robotika*, 7(1), 23–30.
- Falakhi, B., Achmal, E. F., Rizaldi, M., Athallah, R. R. R., & Yudistira, N. (2022). Perbandingan Model AlexNet dan ResNet dalam Klasifikasi Citra Bunga Memanfaatkan Transfer Learning. *Jurnal Ilmu Komputer Dan Agri-Informatika*, 9(1), 70–78.
- Gencer, K. (2025). A Comparative Analysis of EfficientNetB0 and EfficientNetV2 Variants for Brain Tumor Classification Using MRI Images. *International Journal of Innovative Engineering Applications*, 9(1), 1–7.

- Heydarian, M., Doyle, T. E., & Samavi, R. (2022). MLCM: Multi-Label Confusion Matrix. *IEEE*, *10*, 19083–19095.
- Hilmi, A. N., Puspaningrum, E. Y., & Wahanani, H. E. (2024). Implementasi Algoritma K-Nearest Neighbor (KNN) untuk Identifikasi Penyakit pada Tanaman Jeruk Berdasarkan Citra Daun. *Router: Jurnal Teknik Informatika Dan Terapan*, *2*(2), 107–117.
- Huang, Z., Jiang, X., Huang, S., Qin, S., & Yang, S. (2023). An Efficient Convolutional Neural Network-based Diagnosis System for Citrus Fruit Diseases. *Frontiers in Genetics*, *14*, 1–11. <https://doi.org/10.3389/fgene.2023.1253934>
- Irvai, M., & Mahdalena, D. (2025). Penerapan Teknik Masking dan Augmentasi pada Arsitektur CNN dan MobileNetV2 untuk Klasifikasi Fase Pertumbuhan Tomat. *Jurnal Teknik Informatika Unika Santo Thomas (JTIUST)*, *10*(01), 60–67.
- Li, H., Chaudhari, P., Yang, H., Lam, M., Ravichandran, A., Bhotika, R., & Soatto, S. (2020). Rethinking the Hyperparameters for Fine-Tuning. *8th International Conference on Learning Representations, ICLR 2020*, 1–20.
- Min, H. J., Qin, J., Yadav, P. K., Frederick, Q., Burks, T., Dewdney, M., Baek, I., & Kim, M. (2024). Classification of Citrus Leaf Diseases Using Hyperspectral Reflectance and Fluorescence Imaging and Machine Learning Techniques. *Horticulturae*, *10*(11). <https://doi.org/10.3390/horticulturae10111124>
- Muhammad, F., Arimurthy, A. M., & Chahyati, D. (2023). Transfer Learning dengan Metode Fine Tuning pada Model Network VGG16 dan ResNet50. *Indonesian Journal of Computer Science*, *12*(2), 284–301.
- Murlena, M., & Syahindra, W. (2024). Application of the Naïve Bayes Algorithm in Classifying the Reading Interests of Regional Library Visitors. *Knowbase : International Journal of Knowledge in Database*, *4*(1), 94–105. <https://doi.org/10.30983/knowbase.v4i1.8680>
- Nugroho, S. A., Salim, A., & Jumiatur. (2023). Pengaruh Herbrisida Nabari Untuk Menekan Pertumbuhan Gulma *Tridax Procumbens* Pada Kebun Jeruk. *Jurnal Biosense*, *6*(2), 255–264.
- Prianka Vedanty, P., Windu Antara Kesiman, M., & Gede Sunarya, I. M. (2025). Pengaruh Data Augmentasi Pada Identifikasi Penyakit Daun Tanaman Obat Menggunakan K-Nearest Neighbor. *JATI (Jurnal Mahasiswa Teknik Informatika)*, *9*(2), 2094–2100.
- Rahman, A., Salim, M., & Riadi, I. (2025). Klasifikasi Citra Spesies Bunga Di Indonesia Berbasis Convolutional Neural Network Menggunakan Teknik Transfer Learning. *Jurnal Software Engineering and Computational Intelligence*, *2*(2), 92–100.

- Ramanjot, Mittal, U., Wadhawan, A., Singla, J., Jhanjhi, N. Z., Ghoniem, R. M., Ray, S. K., & Abdelmaboud, A. (2023). Plant Disease Detection and Classification: A Systematic Literature Review. *Sensors*, 23(10). <https://doi.org/10.3390/s23104769>
- Rijal, M., Yani, A. M., & Rahman, A. (2024). Deteksi Citra Daun Untuk Klasifikasi Penyakit Padi Menggunakan Pendekatan Deep Learning Dengan Model CNN. *Jurnal Teknologi Terpadu*, 10(1), 56–62.
- Riswandi, Jamiah, R., Mardhatillah, N., & Hamid, H. P. (2021). Klasifikasi Penyakit Pada Citra Daun Jeruk Menggunakan Arsitektur MobileNet berbasis Mobile Platform. *Jurnal Fokus Elektroda: Energi Listrik, Telekomunikasi, Komputer, Elektronika Dan Kendali*, 6(4), 212–215.
- Rizal, M., Saputra, V. J., Maulana, D. I., Budiman, F., & Sugiarto, E. (2025). Deteksi Awal Penyakit Tanaman Berbasis Citra Daun: Studi Perbandingan Algoritme SVM dan CNN. *IRCS: Integrative Research in Computer Science*, 1(1), 61–76.
- Rukuna, A., Zambuk, F. U., Gital, A. Y., & Bello, M. (2025). Citrus Diseases Detection and Classification Based on EfficientNet-B5. *Systems and Soft Computing*, 7, 200199.
- Shojaenia, M., Hosseini, A., Naderi, M., Baloutch, B., Yekta, M. S., Akbarpour, L., & Moghaddasi, H. (2025). A Comprehensive Overview: Deep Learning Approaches to Central Serous Chorioretinopathy Diagnosis. *BMC Ophthalmology*, 25(1), 549.
- Siagian, S., Ibnutama, K., & Mahyuni, R. (2022). Implementasi Metode Ekstraksi Ciri Warna Untuk Mendeteksi Kematangan Buah Jeruk. *Jurnal Sistem Informasi Triguna Dharma*, 1(6), 898–905.
- Siddiqi, R. (2019). Effectiveness of Transfer Learning and Fine Tuning in Automated Fruit Image Classification. *ACM International Conference Proceeding Series*, 91–100.
- Soleha, F., Hidayat, A., & Zulus, A. (2025). Hyperparameter Tuning Dalam Deteksi Penyakit Daun Jeruk Dengan Pendekatan Transfer Learning. *Journal of Informatics, Electrical and Electronics Engineering*, 4(3), 100–107.
- Solihin, S., Raharja, A. R., Putra, V. H. C., & Al-Husaini, M. (2026). Perbandingan Decision Tree dan Logistic Regression Untuk Deteksi Penyakit Daun Multispesies Menggunakan Pendekatan Fitur Hibrida Berbasis Citra. *Technologia: Jurnal Ilmiah*, 17(1), 142–151.
- Swasono, D. I., Wijaya, M. A. R., & Hidayat, M. A. (2023). Klasifikasi Penyakit pada Citra Buah Jeruk Menggunakan Convolutional Neural Networks (CNN) dengan Arsitektur Alexnet. *INFORMAL: Informatics Journal*, 8(1), 68.
- Tan, M., & Le, Q. V. (2021). EfficientNetV2: Smaller Models and Faster Training. *Proceedings of Machine Learning Research*.

- Wardani, K. R., & Leonardi, L. (2023). Klasifikasi Penyakit pada Daun Anggur menggunakan Metode Convolutional Neural Network. *Jurnal Tekno Insentif*, 17(2), 112–126.
- Wicaksono, R. C., & Endarto, O. (2019). Peran Kaolin dalam Pengendalian Hama Thrips Pada Buah Jeruk. *Jurnal Agronida*, 5(1), 7–11.
- Zafar, A., Aamir, M., Mohd Nawi, N., Arshad, A., Riaz, S., Alruban, A., Dutta, A. K., & Almotairi, S. (2022). A Comparison of Pooling Methods for Convolutional Neural Networks. *Applied Sciences*, 12(17), 8643.