

Comparative analysis of convolutional neural network architectures for guava disease classification

Rahman Wahabi Hasibuan¹, Muhammad Amin Rais², Mutiara Akbar Nasution³

^{1,2,3}Magister Teknik Informatika, Universitas Sumatera Utara, Indonesia

Email: rahmanwahabi@students.usu.ac.id; gamirai@yahoo.com; mutiaraakbar@students.usu.ac.id

ABSTRAK

Penelitian ini bertujuan untuk membandingkan kinerja arsitektur *Convolutional Neural Network* (CNN), yaitu EfficientNetB0 dan EfficientNetV2-S, dalam mengklasifikasikan kondisi buah jambu biji (*Psidium guajava* L.) berdasarkan citra digital. Dataset yang digunakan terdiri atas tiga kelas, yaitu antraknosa (*anthracnose*), serangan lalat buah (*fruit flies*), dan buah sehat (*healthy fruits*). Ketidakseimbangan kelas ditangani menggunakan teknik *undersampling*, sedangkan kedua model dikembangkan dengan pendekatan *transfer learning* menggunakan bobot pralatih ImageNet dan dilatih selama 30 *epoch*. Kinerja model dievaluasi menggunakan akurasi, presisi, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa EfficientNetB0 memperoleh akurasi validasi sebesar 99,49% dengan *loss* sebesar 0,0124, sedangkan EfficientNetV2-S memperoleh akurasi validasi sebesar 94,17% dengan *loss* sebesar 0,2153. Hasil *classification report* juga menunjukkan bahwa EfficientNetB0 menghasilkan *F1-score* sebesar 0,99–1,00 pada ketiga kelas, sedangkan EfficientNetV2-S memperoleh *F1-score* sebesar 0,92–0,96. Berdasarkan hasil tersebut, EfficientNetB0 menunjukkan kinerja klasifikasi yang lebih tinggi dibandingkan EfficientNetV2-S pada dataset dan konfigurasi pelatihan yang digunakan dalam penelitian ini.

Kata Kunci: convolutional neural network; klasifikasi penyakit jambu biji; efficientnet-b0; efficientnetv2-s; deep learning

ABSTRACT

This study aims to compare the performance of two Convolutional Neural Network (CNN) architectures, EfficientNetB0 and EfficientNetV2-S, in classifying guava (*Psidium guajava* L.) conditions based on digital images. The dataset consists of three classes: anthracnose, fruit fly infestation, and healthy fruits. Class imbalance was addressed using an undersampling technique, while both models were developed using a transfer learning approach with ImageNet pre-trained weights and trained for 30 epochs. Model performance was evaluated using accuracy, precision, recall, and F1-score. The results showed that EfficientNetB0 achieved a validation accuracy of 99.49% with a loss of 0.0124, whereas EfficientNetV2-S achieved a validation accuracy of 94.17% with a loss of 0.2153. The classification report further showed that EfficientNetB0 achieved F1-scores ranging from 0.99 to 1.00 across the three classes, while EfficientNetV2-S achieved F1-scores ranging from 0.92 to 0.96. Based on these results, EfficientNetB0 demonstrated higher classification performance than EfficientNetV2-S on the dataset and training configuration used in this study.

Keywords: convolutional neural network; guava disease classification; EfficientNet-B0; EfficientNetV2-S; deep learning

Corresponding Author:

Rahman Wahabi Hasibuan,
Universitas Sumatera Utara,
Jl. Universitas No. 9, Kampus USU, Kec. Medan Baru, Kota Medan, Sumatera
Utara 20155, Indonesia
Email: rahmanwahabi@students.usu.ac.id



1. INTRODUCTION

Jambu biji (*Psidium guajava* L.) merupakan salah satu komoditas buah tropis yang dibudidayakan secara luas di berbagai negara, termasuk Indonesia (Hanik et al., 2023). Budidaya jambu biji termasuk dalam bidang hortikultura yang mencakup pengelolaan tanaman buah, sayuran, tanaman hias, dan tanaman obat.

Hortikultura merupakan bagian dari sektor pertanian yang memiliki peran dalam pemenuhan kebutuhan pangan dan pengembangan komoditas pertanian (Pitaloka, 2020).

Salah satu permasalahan dalam budidaya jambu biji adalah serangan hama dan penyakit yang dapat memengaruhi kondisi buah. Lalat buah (*fruit fly*), terutama *Bactrocera* spp., dapat menimbulkan noda hitam dan lubang kecil pada permukaan buah. Lalat buah betina meletakkan telur pada buah yang kemudian berkembang menjadi larva dan merusak jaringan hingga menyebabkan pembusukan. Selain serangan lalat buah, antraknosa (*anthracnose*) merupakan salah satu penyakit yang dapat menyerang jambu biji. Penyakit yang disebabkan oleh *Colletotrichum gloeosporioides* tersebut dapat ditandai dengan munculnya bercak hitam yang berkembang pada permukaan buah hingga menyebabkan kerusakan dan pembusukan (Hanik et al., 2023). Perbedaan karakteristik visual antara buah yang terserang penyakit, hama, dan buah sehat membuka peluang pemanfaatan teknologi pengolahan citra untuk membantu proses identifikasi secara otomatis.

Perkembangan *deep learning* memberikan pendekatan yang dapat digunakan untuk melakukan klasifikasi objek berdasarkan pola yang terdapat pada data. *Deep learning* merupakan bagian dari *machine learning* yang menggunakan jaringan saraf berlapis untuk mempelajari representasi dan pola dari data (Raup et al., 2022). Dalam klasifikasi berbasis citra, salah satu pendekatan yang banyak digunakan adalah *Convolutional Neural Network* (CNN). CNN memiliki kemampuan untuk mempelajari fitur visual secara hierarkis sehingga dapat digunakan untuk berbagai tugas klasifikasi citra, termasuk identifikasi kondisi tanaman dan buah (Hasibuan et al., 2025).

Salah satu keluarga arsitektur CNN yang dikembangkan dengan mempertimbangkan efisiensi komputasi dan kinerja adalah EfficientNet. EfficientNetB0 merupakan varian dasar EfficientNet yang dirancang untuk memperoleh keseimbangan antara kedalaman, lebar, dan resolusi jaringan. Arsitektur ini relatif ringkas dan dapat memanfaatkan bobot hasil prapelatihan (*pre-trained weights*) pada ImageNet melalui pendekatan *transfer learning*. Penelitian terdahulu menunjukkan bahwa EfficientNetB0 memiliki potensi untuk klasifikasi penyakit buah. Maylianti et al. (2025), misalnya, membandingkan EfficientNetB0 dan ResNet50 dalam mendeteksi penyakit pada buah kakao dan memperoleh akurasi sebesar 96% pada pembagian data 80:20. EfficientNetB0 tetap menunjukkan kinerja yang kompetitif dengan jumlah parameter yang lebih efisien dibandingkan ResNet50. Penerapan pendekatan CNN pada komoditas buah juga ditunjukkan oleh Huang et al. (2023) melalui pengembangan sistem diagnosis penyakit buah jeruk berbasis citra. Temuan tersebut semakin menunjukkan potensi pendekatan berbasis CNN untuk mendukung identifikasi penyakit buah secara otomatis.

Pengembangan lebih lanjut dari keluarga EfficientNet menghasilkan EfficientNetV2 yang dirancang untuk meningkatkan efisiensi dan kecepatan proses pelatihan. EfficientNetV2 menggunakan kombinasi *Fused-MBConv* dan MBConv serta menerapkan pendekatan *training-aware neural architecture search* dan strategi *scaling* untuk menghasilkan arsitektur yang lebih efisien (Tan & Le, 2021). Salah satu variannya, EfficientNetV2-S, telah digunakan dalam penelitian klasifikasi penyakit tanaman. Ye et al. (2022) mengembangkan modifikasi EfficientNetV2 untuk identifikasi penyakit singkong dan melaporkan akurasi hingga 99,56%. Hasil tersebut menunjukkan potensi keluarga EfficientNetV2 dalam menangani klasifikasi penyakit tanaman berbasis citra.


Meskipun EfficientNetB0 dan EfficientNetV2-S berasal dari keluarga arsitektur yang sama, keduanya memiliki karakteristik desain yang berbeda. EfficientNetB0 mengutamakan efisiensi melalui struktur MBConv, sedangkan EfficientNetV2-S mengembangkan desain tersebut melalui penggunaan *Fused-MBConv* pada bagian tertentu dari jaringan untuk meningkatkan efisiensi pelatihan. Perbedaan karakteristik tersebut menyebabkan kinerja kedua arsitektur tidak dapat ditentukan hanya berdasarkan kompleksitas atau generasi arsitekturnya, tetapi perlu dievaluasi pada tugas klasifikasi dan dataset yang sama.

Berdasarkan literatur yang digunakan dalam penelitian ini, EfficientNetB0 maupun EfficientNetV2 telah diterapkan pada berbagai tugas klasifikasi penyakit tanaman. Namun, perbandingan langsung antara EfficientNetB0 dan EfficientNetV2-S pada klasifikasi kondisi buah jambu biji ke dalam kelas antraknosa (*anthracnose*), serangan lalat buah (*fruit flies*), dan buah sehat (*healthy fruits*) belum dibahas dalam literatur yang digunakan pada penelitian ini. Oleh karena itu, penelitian ini melakukan analisis komparatif terhadap kedua arsitektur menggunakan dataset dan konfigurasi evaluasi yang sama. Perbandingan tersebut diperlukan untuk mengetahui bagaimana perbedaan karakteristik kedua arsitektur tercermin pada kinerja klasifikasi citra jambu biji.

Penelitian ini bertujuan untuk membandingkan kinerja EfficientNetB0 dan EfficientNetV2-S dalam mengklasifikasikan citra jambu biji ke dalam tiga kategori, yaitu antraknosa, serangan lalat buah, dan buah sehat. Kinerja kedua model dievaluasi menggunakan akurasi (*accuracy*), presisi (*precision*), *recall*, dan *F1-score*. Melalui perbandingan tersebut, penelitian ini diharapkan dapat memberikan gambaran mengenai arsitektur yang menunjukkan kinerja klasifikasi lebih tinggi pada dataset dan konfigurasi penelitian yang digunakan.

2. RESEARCH METHOD

Metodologi penelitian ini disusun secara sistematis untuk membandingkan kinerja dua arsitektur *Convolutional Neural Network* (CNN), yaitu EfficientNetB0 dan EfficientNetV2-S, dalam mengklasifikasikan penyakit pada buah jambu biji berdasarkan citra digital. Tahapan penelitian meliputi pengumpulan data, prapemrosesan data, analisis dan perancangan arsitektur model, pelatihan model, serta evaluasi kinerja. Setiap tahapan dilakukan untuk memperoleh hasil perbandingan yang dapat menggambarkan kemampuan kedua arsitektur dalam mengenali karakteristik visual dari masing-masing kelas. Alur penelitian secara keseluruhan disajikan pada Gambar 1.



Gambar 1. Alur Penelitian

A. Pengumpulan Data

Penelitian ini menggunakan dataset publik yang diperoleh dari repositori Mendeley Data dan dipublikasikan oleh Amin et al. (2024). Dataset tersebut terdiri atas 3.784 citra buah jambu biji yang dikelompokkan ke dalam tiga kategori, yaitu antraknosa (*anthracnose*), serangan lalat buah (*fruit flies*), dan buah sehat (*healthy fruits*). Setiap kategori merepresentasikan kondisi visual buah jambu biji yang berbeda sehingga dapat digunakan sebagai dasar pengembangan model klasifikasi berbasis citra.

Dataset yang digunakan telah dilengkapi label kelas untuk mendukung pendekatan pembelajaran terawasi (*supervised learning*). Dalam pendekatan ini, model dilatih menggunakan citra beserta label kategorinya untuk mempelajari karakteristik visual yang membedakan setiap kelas. Contoh citra dari masing-masing kategori ditampilkan pada Tabel 1.

Tabel 1. Dataset Jambu Biji

Antraknosa (<i>Anthracnose</i>)	Lalat Buah (<i>Fruit Flies</i>)	Buah Sehat (<i>Healthy Fruits</i>)
		

B. Prapemrosesan Data

Tahap prapemrosesan (*data preprocessing*) dilakukan untuk mempersiapkan citra sebelum digunakan dalam proses pelatihan dan evaluasi model. Salah satu permasalahan yang ditangani pada tahap ini adalah ketidakseimbangan jumlah citra antar kelas. Ketidakseimbangan tersebut dapat memengaruhi proses pembelajaran karena model berpotensi lebih banyak mempelajari karakteristik kelas yang memiliki jumlah sampel lebih besar.

Untuk mengatasi permasalahan tersebut, penelitian ini menerapkan teknik *undersampling* dengan mengurangi jumlah citra pada kelas yang memiliki sampel lebih banyak. Proses ini dilakukan untuk memperoleh distribusi data yang seimbang, yaitu sebanyak 649 citra pada masing-masing kelas antraknosa, lalat buah, dan buah sehat. Dengan demikian, setiap kelas memiliki jumlah sampel yang sama untuk mendukung proses pengembangan model.

Selain penyeimbangan kelas, tahap prapemrosesan mencakup penyesuaian ukuran citra (*image resizing*) agar seluruh citra memiliki dimensi yang seragam sesuai dengan kebutuhan masukan model. Pengolahan citra juga dilakukan untuk meningkatkan karakteristik visual dan mendukung proses ekstraksi fitur. Selanjutnya, dataset dibagi menjadi data pelatihan (*training data*) dan data validasi (*validation data*) dengan proporsi 70:30 sebagaimana ditunjukkan pada Tabel 2.

Tabel 2. Pembagian Dataset

Jenis Data	Persentase
Data pelatihan (<i>training</i>)	70%
Data validasi (<i>validation</i>)	30%

Dataset yang telah diseimbangkan selanjutnya dibagi menjadi data pelatihan (*training*) dan data validasi (*validation*) dengan proporsi 70:30. Data pelatihan digunakan dalam proses pembelajaran model, sedangkan data validasi digunakan untuk mengevaluasi kinerja model selama proses pengembangan. Pembagian tersebut digunakan secara konsisten pada EfficientNetB0 dan EfficientNetV2-S sehingga kedua arsitektur dievaluasi menggunakan skema pembagian data yang sama.

C. Analisis dan Perancangan Model CNN

Tahap analisis dan perancangan model berfokus pada pengembangan dua arsitektur *Convolutional Neural Network* (CNN), yaitu EfficientNetB0 dan EfficientNetV2-S. Kedua arsitektur diimplementasikan menggunakan pustaka Keras dengan pendekatan *transfer learning* untuk memanfaatkan pengetahuan yang telah diperoleh melalui proses prapengetahuan pada dataset ImageNet. Pemilihan kedua arsitektur didasarkan pada karakteristiknya yang dirancang untuk menghasilkan representasi fitur secara efisien melalui struktur jaringan konvolusional.

EfficientNetB0 merupakan arsitektur dari keluarga EfficientNet yang mengutamakan keseimbangan antara kompleksitas model dan kemampuan ekstraksi fitur. Sementara itu, EfficientNetV2-S dikembangkan sebagai penyempurnaan generasi sebelumnya dengan penekanan pada efisiensi proses pelatihan. Kedua arsitektur digunakan untuk menyelesaikan tugas klasifikasi yang sama, yaitu mengidentifikasi tiga kategori kondisi buah jambu biji berdasarkan citra digital.

1) Arsitektur EfficientNetB0

EfficientNetB0 merupakan arsitektur CNN yang dikembangkan berdasarkan blok *Mobile Inverted Bottleneck Convolution* (MBConv). Struktur jaringan diawali dengan lapisan konvolusi berukuran 3×3 sebagai lapisan awal (*stem*) untuk mengekstraksi fitur dasar dari citra masukan. Selanjutnya, fitur diproses melalui tujuh tahapan blok MBConv yang disusun secara berurutan.

Tahap pertama menggunakan MBConv1, sedangkan tahap kedua hingga ketujuh menggunakan MBConv6 dengan rasio ekspansi sebesar enam kali. Blok-blok tersebut memanfaatkan variasi ukuran kernel 3×3 dan 5×5 untuk mengekstraksi karakteristik visual pada berbagai tingkat representasi. Mekanisme *depthwise separable convolution* digunakan untuk meningkatkan efisiensi komputasi, sedangkan *squeeze-and-excitation* berfungsi memberikan penekanan pada kanal fitur yang relevan. Selain itu, koneksi residual diterapkan pada blok yang memenuhi persyaratan kesesuaian dimensi untuk mendukung aliran informasi selama proses pembelajaran.

Selanjutnya melalui seluruh tahapan ekstraksi fitur, representasi yang dihasilkan diteruskan ke bagian klasifikasi untuk menghasilkan prediksi kelas. Struktur tersebut memungkinkan EfficientNetB0 mempelajari karakteristik visual citra dengan penggunaan parameter yang relatif efisien. Arsitektur EfficientNetB0 ditampilkan pada Gambar 2.



Gambar 2. Arsitektur EfficientNetB0 (Raihan et al., 2023)


2) Arsitektur EfficientNetV2-S

EfficientNetV2-S merupakan arsitektur CNN yang dikembangkan untuk meningkatkan efisiensi pelatihan dan kemampuan ekstraksi fitur dibandingkan dengan generasi EfficientNet sebelumnya. Arsitektur ini menggabungkan penggunaan blok *Fused-MBConv* dan MBConv pada tahapan jaringan yang berbeda untuk mengoptimalkan proses pembelajaran fitur visual (Tan & Le, 2021).

Proses pengolahan citra diawali dengan lapisan konvolusi berukuran 3×3 sebagai lapisan awal (*stem*) untuk mengekstraksi fitur dasar. Selanjutnya, fitur diproses melalui serangkaian blok *Fused-MBConv* yang menggabungkan operasi konvolusi untuk meningkatkan efisiensi pemrosesan pada tahapan awal jaringan. Pada proses tersebut, resolusi spasial secara bertahap dikurangi, sedangkan jumlah kanal fitur ditingkatkan untuk menghasilkan representasi visual yang lebih kompleks.

Tahapan berikutnya menggunakan blok MBConv yang dilengkapi mekanisme *Squeeze-and-Excitation* (SE). Mekanisme ini membantu jaringan memberikan perhatian lebih besar pada kanal fitur yang relevan terhadap proses klasifikasi. Seiring bertambahnya kedalaman jaringan, resolusi spasial mengalami penurunan, sedangkan jumlah kanal fitur meningkat hingga mencapai 256 pada tahapan tertentu.

Pada bagian akhir, fitur diproses melalui lapisan konvolusi berukuran 1×1 sebelum diteruskan ke lapisan *global average pooling* dan lapisan terhubung penuh (*fully connected layer*) untuk menghasilkan prediksi kelas. Kombinasi blok *Fused-MBConv* dan MBConv menjadi karakteristik utama EfficientNetV2-S dalam mendukung efisiensi pelatihan dan pembentukan representasi fitur. Arsitektur EfficientNetV2-S ditampilkan pada Gambar 3.



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

D. Pelatihan Model

Tahap pelatihan model dilakukan menggunakan dua arsitektur CNN, yaitu EfficientNetB0 dan EfficientNetV2-S, dengan pendekatan *transfer learning*. Pendekatan ini memanfaatkan bobot hasil prapenelitian (*pre-trained weights*) pada dataset ImageNet sebagai dasar pembelajaran untuk tugas klasifikasi penyakit buah jambu biji. Penggunaan bobot pralatih bertujuan memanfaatkan representasi fitur visual yang telah dipelajari sebelumnya sehingga model dapat digunakan untuk mengenali karakteristik citra pada dataset penelitian.

Dalam proses pengolahan citra, penelitian ini menerapkan teknik *Unsharp Masking* dan *Contrast Limited Adaptive Histogram Equalization* (CLAHE). *Unsharp Masking* digunakan untuk meningkatkan ketajaman citra dengan memperjelas batas dan detail objek, sedangkan CLAHE digunakan untuk meningkatkan kontras lokal pada citra. Kedua teknik tersebut bertujuan memperjelas karakteristik visual yang dapat mendukung proses ekstraksi fitur oleh model CNN.

Proses optimisasi parameter model menggunakan algoritme Adam dengan tingkat pembelajaran (*learning rate*) sebesar 0,0001. Algoritme Adam digunakan untuk memperbarui bobot jaringan berdasarkan gradien fungsi kerugian (*loss function*) selama proses pelatihan. Kedua model dilatih selama 30 *epoch*, yaitu 30 siklus pembelajaran terhadap keseluruhan data pelatihan.

Selama proses pelatihan, kinerja model diamati melalui perubahan nilai akurasi dan *loss* pada data pelatihan dan validasi. Nilai akurasi digunakan untuk menggambarkan proporsi prediksi yang benar, sedangkan *loss* menunjukkan tingkat kesalahan model berdasarkan fungsi kerugian yang digunakan. Hasil pelatihan kedua arsitektur selanjutnya dibandingkan untuk menganalisis perbedaan kemampuan pembelajaran dan kinerja klasifikasi berdasarkan konfigurasi penelitian yang diterapkan.

E. Evaluasi Model

Tahap evaluasi dilakukan untuk mengukur dan membandingkan kinerja EfficientNetB0 dan EfficientNetV2-S dalam mengklasifikasikan citra buah jambu biji ke dalam tiga kategori, yaitu antraknosa (*anthracnose*), lalat buah (*fruit flies*), dan buah sehat (*healthy fruits*). Evaluasi dilakukan berdasarkan hasil prediksi pada data validasi yang telah ditetapkan dalam pembagian dataset.

Kinerja masing-masing arsitektur dianalisis secara kuantitatif menggunakan empat metrik utama, yaitu akurasi (*accuracy*), presisi (*precision*), *recall*, dan *F1-score*. Selain itu, laporan klasifikasi (*classification report*) digunakan untuk menampilkan kinerja model pada setiap kategori. Matriks konfusi (*confusion matrix*) merupakan salah satu dasar perhitungan metrik tersebut karena menggambarkan hubungan antara kelas aktual dan kelas prediksi.

1) Akurasi (Accuracy)

Akurasi digunakan untuk mengukur proporsi keseluruhan prediksi yang benar terhadap jumlah data yang dievaluasi. Pada klasifikasi multikelas, akurasi dihitung berdasarkan jumlah prediksi benar dari seluruh kelas dibandingkan dengan jumlah keseluruhan sampel. Bentuk dasar persamaan akurasi adalah sebagai berikut.

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

2) Presisi (Precision)

Presisi digunakan untuk mengukur ketepatan model dalam menghasilkan prediksi pada suatu kelas. Metrik ini menunjukkan proporsi data yang benar-benar termasuk dalam kelas tertentu dibandingkan dengan seluruh data yang diprediksi sebagai kelas tersebut. Persamaan presisi adalah sebagai berikut.

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

3) Recall

Recall digunakan untuk mengukur kemampuan model dalam mengidentifikasi seluruh sampel yang sebenarnya termasuk dalam suatu kelas. Nilai *recall* yang tinggi menunjukkan bahwa sebagian besar sampel dari kelas tersebut berhasil dikenali dengan benar. Persamaan *recall* adalah sebagai berikut.

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

4) F1-score

F1-score merupakan rata-rata harmonik antara presisi dan *recall* yang digunakan untuk menggambarkan keseimbangan kedua metrik tersebut. Metrik ini memberikan gambaran mengenai

(Rahman Wahabi Hasibuan)

kemampuan model dalam mempertahankan ketepatan prediksi sekaligus mengenali sampel dari kelas yang dievaluasi. Persamaan *F1-score* adalah sebagai berikut.

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

Keempat metrik tersebut didasarkan pada nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). TP menunjukkan jumlah sampel suatu kelas yang berhasil diprediksi dengan benar, sedangkan TN menunjukkan jumlah sampel di luar kelas tersebut yang diprediksi dengan benar. FP merupakan jumlah sampel dari kelas lain yang keliru diprediksi sebagai kelas yang sedang dievaluasi, sementara FN menunjukkan jumlah sampel dari kelas tersebut yang keliru diprediksi sebagai kelas lain.

Karena penelitian ini melibatkan tiga kelas, perhitungan presisi, *recall*, dan *F1-score* dapat dijelaskan menggunakan pendekatan *one-vs-rest*, yaitu dengan mengevaluasi satu kelas sebagai kelas positif dan menggabungkan kelas lainnya sebagai kelas negatif. Pendekatan tersebut memungkinkan pengukuran kinerja model secara terpisah pada setiap kategori penyakit maupun buah sehat.

Selain menggunakan metrik evaluasi, penelitian ini juga menganalisis grafik akurasi dan *loss* selama proses pelatihan untuk mengamati perkembangan kemampuan pembelajaran kedua arsitektur. Hasil evaluasi kemudian dibandingkan berdasarkan nilai metrik dan karakteristik kurva pelatihan yang diperoleh. Perbandingan tersebut digunakan untuk menentukan arsitektur yang menunjukkan kinerja klasifikasi lebih tinggi pada dataset dan konfigurasi penelitian yang digunakan.

3. RESULTS AND DISCUSSION

Penelitian ini membandingkan kinerja dua arsitektur *Convolutional Neural Network* (CNN), yaitu EfficientNetB0 dan EfficientNetV2-S, dalam mengklasifikasikan penyakit pada buah jambu biji berdasarkan citra digital. Kedua model digunakan untuk mengidentifikasi tiga kategori, yaitu antraknosa (*anthracnose*), serangan lalat buah (*fruit flies*), dan buah sehat (*healthy fruits*). Perbandingan dilakukan berdasarkan hasil pelatihan selama 30 *epoch* serta evaluasi menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*. Analisis juga mencakup perkembangan akurasi dan *loss* selama pelatihan untuk mengamati karakteristik pembelajaran masing-masing arsitektur.

A. Hasil Pelatihan dan Validasi Model

Proses pelatihan dilakukan untuk mengembangkan kemampuan EfficientNetB0 dan EfficientNetV2-S dalam mengenali karakteristik visual dari setiap kategori citra jambu biji. Selama pelatihan, kedua model memperbarui parameter jaringan berdasarkan data pelatihan, sedangkan data validasi digunakan untuk memantau kinerja model pada citra yang tidak digunakan dalam pembaruan bobot. Hasil pelatihan diamati melalui perubahan nilai akurasi dan *loss* pada setiap *epoch*.



EfficientNetB0

EfficientNetV2-S

Gambar 4. Hasil Pelatihan EfficientNetB0 dan EfficientNetV2-S

Berdasarkan Gambar 4, kedua arsitektur menunjukkan perkembangan kinerja yang berbeda selama 30 *epoch* pelatihan. EfficientNetB0 mencapai akurasi pelatihan sebesar 0,9992 atau 99,92% dan akurasi validasi sebesar 0,9949 atau 99,49% pada *epoch* terakhir. Nilai *loss* pelatihan dan validasi masing-masing tercatat sebesar 0,0051 dan 0,0124. Hasil tersebut menunjukkan bahwa EfficientNetB0 mampu mencapai tingkat ketepatan klasifikasi yang tinggi dengan nilai kesalahan relatif rendah pada data pelatihan maupun validasi.


Sementara itu, EfficientNetV2-S memperoleh akurasi pelatihan sebesar 0,9253 atau 92,53% dan akurasi validasi sebesar 0,9417 atau 94,17% pada *epoch* terakhir. Nilai *loss* pelatihan dan validasi masing-masing sebesar 0,2544 dan 0,2153. Meskipun akurasi validasinya lebih rendah dibandingkan EfficientNetB0,

hasil tersebut menunjukkan bahwa EfficientNetV2-S tetap mampu mempelajari karakteristik visual dari ketiga kategori citra.

Perbandingan hasil pada *epoch* terakhir memperlihatkan bahwa EfficientNetB0 memiliki akurasi validasi lebih tinggi sebesar 5,32 poin persentase dibandingkan EfficientNetV2-S. Selain itu, nilai *loss* validasi EfficientNetB0 juga lebih rendah. Perbedaan tersebut menunjukkan bahwa EfficientNetB0 menghasilkan kinerja klasifikasi yang lebih baik pada dataset dan konfigurasi pelatihan yang digunakan dalam penelitian ini.

B. Hasil Evaluasi Model


Evaluasi dilakukan untuk menganalisis kemampuan kedua arsitektur dalam mengklasifikasikan citra buah jambu biji. Analisis mencakup perkembangan akurasi dan *loss* selama proses pelatihan serta hasil laporan klasifikasi (*classification report*) yang menunjukkan kinerja model pada masing-masing kelas. Melalui evaluasi tersebut, perbandingan tidak hanya didasarkan pada akurasi keseluruhan, tetapi juga mempertimbangkan kemampuan model dalam mengenali setiap kategori.



Gambar 5. Grafik Hasil Akurasi dan Loss pada EfficientNetB0

Gambar 5 menunjukkan perkembangan akurasi dan *loss* EfficientNetB0 selama 30 *epoch*. Pada grafik akurasi, terlihat bahwa akurasi pelatihan meningkat secara cepat pada beberapa *epoch* awal, kemudian cenderung stabil mendekati 100%. Akurasi validasi menunjukkan pola serupa dengan peningkatan yang relatif cepat dan fluktuasi kecil pada tahap akhir pelatihan. Kedekatan kedua kurva menunjukkan bahwa kinerja model pada data pelatihan dan validasi relatif konsisten selama proses pembelajaran.

Pada grafik *loss*, nilai kesalahan pelatihan dan validasi mengalami penurunan tajam pada tahap awal, kemudian berangsur stabil pada nilai yang rendah. Pola tersebut menunjukkan bahwa proses optimisasi mampu mengurangi kesalahan prediksi seiring bertambahnya jumlah *epoch*. Kurva pelatihan dan validasi yang relatif berdekatan juga tidak memperlihatkan indikasi kuat terjadinya *overfitting* selama pelatihan yang diamati.



Gambar 6. Grafik Hasil Akurasi dan Loss pada EfficientNetV2-S

Gambar 6 memperlihatkan perkembangan akurasi dan *loss* EfficientNetV2-S selama 30 *epoch*. Berbeda dengan EfficientNetB0, peningkatan akurasi EfficientNetV2-S berlangsung lebih bertahap. Pada beberapa *epoch* awal, akurasi pelatihan meningkat cukup cepat, kemudian terus mengalami peningkatan dengan laju yang lebih lambat hingga akhir pelatihan. Akurasi validasi juga menunjukkan kecenderungan meningkat dan mencapai 94,17% pada *epoch* terakhir.

Pada grafik *loss*, nilai kesalahan pelatihan dan validasi mengalami penurunan secara bertahap sepanjang proses pelatihan. Namun, nilai *loss* pada akhir pelatihan masih lebih tinggi dibandingkan EfficientNetB0. Kondisi tersebut menunjukkan bahwa EfficientNetV2-S belum mencapai tingkat kesalahan serendah EfficientNetB0 dalam jumlah *epoch* yang sama. Penurunan *loss* yang masih berlangsung hingga tahap akhir juga mengindikasikan adanya kemungkinan peningkatan kinerja apabila dilakukan penyesuaian konfigurasi pelatihan.

Selain itu, kurva akurasi validasi EfficientNetV2-S cenderung berada sedikit di atas kurva akurasi pelatihan, sedangkan nilai *loss* validasinya relatif lebih rendah. Perbedaan tersebut dapat dipengaruhi oleh karakteristik data, proses regularisasi, atau mekanisme pelatihan yang diterapkan.

Secara keseluruhan, kedua arsitektur menunjukkan perkembangan pembelajaran yang positif selama 30 *epoch*. EfficientNetB0 mencapai akurasi tinggi dan nilai *loss* rendah dalam waktu pelatihan yang diamati, sedangkan EfficientNetV2-S memperlihatkan peningkatan kinerja secara bertahap hingga akhir pelatihan. Temuan ini menunjukkan bahwa EfficientNetB0 memiliki kinerja validasi lebih tinggi pada konfigurasi penelitian yang digunakan, sementara EfficientNetV2-S masih menunjukkan potensi peningkatan melalui optimisasi pelatihan lebih lanjut.

EfficientNetB0			
***** Classification Report *****			
	precision	recall	f1-score
Anthracnose	1.00	1.00	1.00
fruit_fly	1.00	0.98	0.99
healthy_guava	0.99	1.00	0.99
accuracy	0.99		

EfficientNetV2-S			
***** Classification Report *****			
	precision	recall	f1-score
Anthracnose	0.90	0.99	0.94
fruit_fly	0.96	0.89	0.92
healthy_guava	0.97	0.95	0.96
accuracy	0.94		

EfficientNetB0

EfficientNetV2-S

Gambar 7. Classification Report EfficientNetB0 dan EfficientNetV2-S

Berdasarkan Gambar 7, hasil *classification report* menunjukkan perbedaan kinerja kedua arsitektur dalam mengidentifikasi setiap kategori citra. EfficientNetB0 memperoleh akurasi keseluruhan sebesar 0,99, sedangkan EfficientNetV2-S memperoleh akurasi sebesar 0,94. Nilai tersebut menunjukkan bahwa EfficientNetB0 memiliki tingkat ketepatan klasifikasi yang lebih tinggi pada data evaluasi yang digunakan.

Pada kelas antraknosa (*anthracnose*), EfficientNetB0 memperoleh nilai presisi, *recall*, dan *F1-score* masing-masing sebesar 1,00. Hasil tersebut menunjukkan bahwa model mampu mengidentifikasi kelas antraknosa dengan sangat baik pada data evaluasi. Sementara itu, EfficientNetV2-S memperoleh presisi sebesar 0,90, *recall* sebesar 0,99, dan *F1-score* sebesar 0,94. Nilai *recall* yang tinggi menunjukkan bahwa sebagian besar citra antraknosa berhasil dikenali, tetapi nilai presisi yang lebih rendah mengindikasikan bahwa masih terdapat citra dari kategori lain yang diprediksi sebagai antraknosa.

Pada kelas lalat buah (*fruit fly*), EfficientNetB0 menghasilkan presisi sebesar 1,00, *recall* sebesar 0,98, dan *F1-score* sebesar 0,99. Sementara itu, EfficientNetV2-S memperoleh presisi sebesar 0,96, *recall* sebesar 0,89, dan *F1-score* sebesar 0,92. Nilai *recall* EfficientNetV2-S yang lebih rendah menunjukkan bahwa model tersebut belum mampu mengenali seluruh citra lalat buah sebaik EfficientNetB0. Kelas lalat buah juga memiliki *F1-score* terendah pada EfficientNetV2-S, sehingga menjadi kategori yang relatif lebih sulit diklasifikasikan oleh arsitektur tersebut.

Pada kelas buah sehat (*healthy guava*), EfficientNetB0 memperoleh presisi sebesar 0,99, *recall* sebesar 1,00, dan *F1-score* sebesar 0,99. Sementara itu, EfficientNetV2-S menghasilkan presisi sebesar 0,97, *recall* sebesar 0,95, dan *F1-score* sebesar 0,96. Hasil tersebut menunjukkan bahwa kedua model memiliki kemampuan yang baik dalam mengenali buah sehat, meskipun EfficientNetB0 masih menunjukkan kinerja yang lebih tinggi berdasarkan ketiga metrik evaluasi.

Perbandingan nilai *F1-score* pada ketiga kategori menunjukkan bahwa EfficientNetB0 memiliki kinerja yang lebih konsisten, dengan nilai berkisar antara 0,99 hingga 1,00. Sebaliknya, EfficientNetV2-S menghasilkan nilai *F1-score* antara 0,92 hingga 0,96. Perbedaan tersebut menunjukkan bahwa EfficientNetB0 mampu mempertahankan keseimbangan antara presisi dan *recall* secara lebih baik pada setiap kelas dalam evaluasi yang dilakukan.

Berdasarkan keseluruhan hasil evaluasi, EfficientNetB0 menunjukkan kinerja klasifikasi yang lebih tinggi dibandingkan EfficientNetV2-S, baik berdasarkan akurasi validasi, nilai *loss*, maupun metrik evaluasi pada masing-masing kelas. Hasil tersebut menunjukkan bahwa EfficientNetB0 lebih sesuai untuk klasifikasi tiga kondisi buah jambu biji pada konfigurasi penelitian yang digunakan.

4. CONCLUSION

Berdasarkan hasil penelitian, EfficientNetB0 menunjukkan kinerja klasifikasi yang lebih tinggi dibandingkan EfficientNetV2-S dalam mengidentifikasi tiga kategori citra jambu biji, yaitu antraknosa (*anthracnose*), serangan lalat buah (*fruit flies*), dan buah sehat (*healthy fruits*). EfficientNetB0 memperoleh akurasi validasi sebesar 99,49% dengan *loss* sebesar 0,0124, sedangkan EfficientNetV2-S memperoleh akurasi validasi sebesar 94,17% dengan *loss* sebesar 0,2153 pada akhir pelatihan. Hasil *classification report* juga menunjukkan bahwa EfficientNetB0 memiliki kinerja yang lebih konsisten pada ketiga kelas, dengan *F1-score* berkisar antara 0,99–1,00, sedangkan EfficientNetV2-S memperoleh *F1-score* antara 0,92–0,96. Pada EfficientNetV2-S, kelas *fruit fly* memiliki *F1-score* terendah sebesar 0,92, yang menunjukkan bahwa kelas tersebut relatif lebih sulit diklasifikasikan oleh model.

Berdasarkan hasil tersebut, EfficientNetB0 menunjukkan kinerja yang lebih baik dibandingkan EfficientNetV2-S pada dataset dan konfigurasi pelatihan yang digunakan dalam penelitian ini. Penelitian selanjutnya dapat mengembangkan hasil ini melalui optimisasi pelatihan, seperti penyesuaian jumlah *epoch*, penerapan *early stopping* dan *learning rate scheduler*, serta *fine-tuning* model. Pengembangan selanjutnya juga dapat mencakup penggunaan validasi silang, pengujian pada dataset yang lebih beragam, analisis kesalahan klasifikasi, serta evaluasi efisiensi komputasi untuk mendukung potensi implementasi model pada perangkat bergerak.

REFERENSI

- Amin, M. Al, Mahmud, M. I., Rahman, A. Bin, Parvin, M. A., & Mamun, M. A. Al. (2024). *Guava fruit disease dataset* [Data set]. Mendeley Data. <https://data.mendeley.com/datasets/bkdkc4n835>
- Apriliansyah, R., Handayanto, A., & Saputro, N. D. (2025). Penerapan arsitektur EfficientNetB0 pada model convolutional neural network untuk deteksi dini mata katarak. *Journal of Computer Engineering, System and Science*, 10(2), 435–446. <https://doi.org/10.24114/cess.v10i2.66913>
- Hanik, N. R., Hidayati, S. N., Fitriani, R. D. A., Cahyanti, F. A., Oktavianingtyas, D., & Wahyuni, T. (2023). Identification of pests and diseases crystal guava (*Psidium guajava* L.) in Ngargoyoso District, Karanganyar Regency. *Jurnal Biologi Tropis*, 23(3), 127–135. <https://doi.org/10.29303/jbt.v23i3.5021>
- Hasibuan, R., Taufik, I., Al Idrus, S. I., & Indra, Z. (2025). Implementasi convolutional neural network dalam mendeteksi tingkat kematangan buah kakao. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(4), 6479–6487. <https://doi.org/10.36040/jati.v9i4.14116>
- 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, Article 1253934. <https://doi.org/10.3389/fgene.2023.1253934>
- Maylianti, N. P., Wijayakusuma, I. G. N. L., & Wiguna, I. P. C. A. (2025). Comparison of EfficientNet-B0 and ResNet-50 for detecting diseases in cocoa fruit. *Journal of Applied Informatics and Computing*, 9(1), 115–120. <https://doi.org/10.30871/jaic.v9i1.8868>
- Pitaloka, D. (2020). Hortikultura: Potensi, pengembangan dan tantangan. *Jurnal Teknologi Terapan: G-Tech*, 1(1), 1–4. <https://doi.org/10.33379/gtech.v1i1.260>
- Raihan, J., Mahmud, Z., Ridita, S. A., & Bhattacharya, A. (2023). *PhytoCare: A hybrid approach for identifying rice, potato and corn diseases* [Bachelor's thesis, University of Liberal Arts Bangladesh].
- Raup, A., Ridwan, W., Khoeriyah, Y., Supiana, S., & Zaqiah, Q. Y. (2022). Deep learning dan penerapannya dalam pembelajaran. *JiIP - Jurnal Ilmiah Ilmu Pendidikan*, 5(9), 3258–3267. <https://doi.org/10.54371/jiip.v5i9.805>
- Tan, M., & Le, Q. V. (2021). EfficientNetV2: Smaller models and faster training. In *Proceedings of the 38th International Conference on Machine Learning* (Vol. 139, pp. 10096–10106). PMLR.
- Ye, Y., Zhou, H., Yu, H., Hu, H., Zhang, G., Hu, J., & He, T. (2022). An improved EfficientNetV2 model based on visual attention mechanism: Application to identification of cassava disease. *Computational Intelligence and Neuroscience*, 2022, Article 1569911. <https://doi.org/10.1155/2022/1569911>