

Komparasi Kinerja Arsitektur MobileNetV2 dan EfficientNetB0 Untuk Klasifikasi Penyakit Daun Tanaman Kedelai

Lisdiawati*, Siti Mutmainah, Khairunnas

Fakultas Teknik dan Ilmu Komputer, Program Studi Ilmu Komputer, Universitas Muhammadiyah Bima, Bima, Indonesia

Email: ^{1,*}lisdw364@email.com, ²sitmutmainah@umbima.ac.id, ³khairunnas@umbima.ac.id

Email Penulis Korespondensi: lisdw364@email.com

Submitted: 20/05/2026; Accepted: 22/06/2026; Published: 23/06/2026

Abstrak—Penyakit daun kedelai dapat mengurangi kualitas dan produktivitas tanaman, sehingga dibutuhkan metode deteksi yang akurat dan efisien. Penelitian ini bertujuan untuk membandingkan kinerja arsitektur MobileNetV2 dan EfficientNetB0 dalam mengklasifikasikan penyakit daun kedelai menggunakan pendekatan transfer learning berbasis deep learning. Dataset yang digunakan terdiri dari gambar daun kedelai yang dikelompokkan ke dalam beberapa kelas penyakit, kemudian dibagi menjadi data pelatihan (80%), validasi (10%), dan pengujian (10%). Tahap pra-pemrosesan meliputi pengubahan ukuran gambar menjadi 224 × 224 piksel, normalisasi nilai piksel, dan augmentasi data berupa rotasi, pergeseran, pembesaran, dan pembalikan horizontal. Proses pelatihan dilakukan menggunakan optimizer Adam dengan learning rate dan menerapkan Early Stopping untuk mengurangi risiko overfitting. Evaluasi model dilakukan menggunakan matriks kebingungan, akurasi, presisi, recall, dan F1-score. Hasil penelitian menunjukkan bahwa MobileNetV2 memperoleh akurasi sebesar 81%, lebih tinggi daripada EfficientNetB0 yang memperoleh akurasi sebesar 70%. Kontribusi penelitian ini adalah untuk memberikan analisis komparatif tentang efektivitas kedua arsitektur dalam mengklasifikasikan penyakit daun kedelai dan untuk menunjukkan bahwa MobileNetV2 lebih optimal untuk diterapkan pada dataset yang digunakan.

Kata Kunci: MobileNetV2; EfficientNetB0; Klasifikasi Citra; Daun Kedelai; Deep Learning

Abstract—Soybean leaf diseases can reduce the quality and productivity of plants, so an accurate and efficient detection method is needed. This study aims to compare the performance of the MobileNetV2 and EfficientNetB0 architectures in classifying soybean leaf diseases using a deep learning-based transfer learning approach. The dataset used consists of soybean leaf images grouped into several disease classes, then divided into training (80%), validation (10%), and testing (10%) data. The pre-processing stage includes resizing the images to 224 × 224 pixels, normalizing pixel values, and data augmentation in the form of rotation, shifting, zooming, and horizontal flipping. The training process is carried out using the Adam optimizer with a learning rate and applying Early Stopping to reduce the risk of overfitting. Model evaluation is carried out using a confusion matrix, accuracy, precision, recall, and F1-score. The results show that MobileNetV2 obtains an accuracy of 81%, higher than EfficientNetB0 which obtains an accuracy of 70%. The contribution of this study is to provide a comparative analysis of the effectiveness of both architectures in classifying soybean leaf diseases and to show that MobileNetV2 is more optimal for application to the dataset used.

Keywords: MobileNetV2; EfficientNetB0; Image Classification; Soybean Leaves; Deep Learning

1. PENDAHULUAN

Tanaman kedelai (*Glycine max*) termasuk komoditas pangan strategis di Indonesia, dengan nilai ekonomi tinggi sekaligus berperan sebagai sumber protein nabati primer bagi masyarakat luas[1]. Tanaman kedelai ini banyak dijadikan bahan baku utama untuk produksi beragam olahan pangan, seperti tempe, tahu, serta kecap[2]. Selain itu, kedelai juga berperan dalam mendukung ketahanan pangan nasional. Secara *morfologi* tanaman kedelai memiliki batang tegak, daun majemuk berbentuk trifoliat (tiga helai), serta menghasilkan polong yang berisi biji sebagai bagian utama yang dimanfaatkan. Tingginya kebutuhan konsumsi kedelai menuntut adanya peningkatan produktivitas dan kualitas hasil panen agar mampu memenuhi permintaan pasar[3].

Dalam proses budidayanya, tanaman kedelai rentan terhadap serangan berbagai penyakit, seperti *soybean rust*, *bacterial pustule*, dan *leaf spot*, karena disebabkan oleh patogen berupa jamur, bakteri, maupun virus[1]. Penyakit tersebut dapat menimbulkan kerusakan pada bagian daun, batang, hingga polong kedelai, karena berdampak pada penurunan hasil panen secara signifikan[4],[5]. Maka dari itu, identifikasi dini serta klasifikasi penyakit daun sangatlah krusial untuk mengoptimalkan strategi pengendalian dan pencegahan secara efektif. Penyakit pada tanaman kerap menimbulkan kerugian hasil panen tahunan yang signifikan, sehingga mengancam keberlanjutan produksi pertanian dengan risiko penurunan drastis atau bahkan kegagalan panen secara keseluruhan[6],[7]. Penelitian ini menerapkan pendekatan Convolutional Neural Network (CNN) melalui arsitektur MobileNetV2 dan EfficientNetB0 guna melakukan klasifikasi penyakit yang menyerang daun tanaman kedelai.

Convolutional Neural Network (CNN) merupakan algoritma deep learning yang paling sering diterapkan untuk klasifikasi citra. CNN bekerja dengan mengekstrak fitur gambar melalui serangkaian lapisan, mencakup *convolution layer*, fungsi aktivasi, *pooling*, serta *fully connected layer*[8]. CNN mampu mengenali pola seperti tepi, tekstur, dan bentuk secara bertahap hingga menghasilkan prediksi kelas. Dalam penelitian ini digunakan arsitektur *MobileNetV2* dan *EfficientNetB0*[9]. *MobileNetV2* dikenal sebagai model ringan yang dirancang untuk bekerja secara efisien dengan penggunaan sumber daya komputasi yang lebih rendah. *EfficientNetB0* dirancang dengan pendekatan penyeimbangan struktur jaringan sehingga mampu meningkatkan performa tanpa menambah beban komputasi secara berlebihan[10].

Beberapa penelitian sebelumnya telah menerapkan arsitektur CNN seperti *MobileNet* dan *EfficientNet* pada klasifikasi penyakit tanaman maupun objek lainnya dengan tingkat akurasi yang tinggi[11]. Sebagian besar penelitian

tersebut berfokus pada tanaman seperti tomat, kentang, padi, atau teh, serta belum secara khusus membandingkan *MobileNetV2* dan *EfficientNetB0* pada penyakit daun kedelai[5],[10]. penelitian hanya menggunakan satu arsitektur tanpa melakukan analisis komparatif, sehingga belum memberikan gambaran menyeluruh mengenai model yang lebih optimal untuk kasus ini.

Mengadapi permasalahan tersebut, solusi teknologi otomatis dalam identifikasi presisi penyakit daun kedelai kini menjadi prioritas utama. Teknik klasifikasi gambar berbasis Convolutional Neural Network (CNN) telah menunjukkan efektivitas tinggi dalam deteksi pola, didukung oleh performa unggul pada beragam aplikasi praktis. Meski demikian, optimalitas arsitektur CNN khususnya *MobileNetV2* vs *EfficientNetB0* untuk klasifikasi penyakit daun kedelai masih belum terungkap secara definitif. Penelitian ini sehingga dirancang untuk membandingkan secara sistematis kedua arsitektur berdasarkan *metrik akurasi, precision, recall, F1-score*, dan efisiensi komputasi, guna menetapkan model paling sesuai.

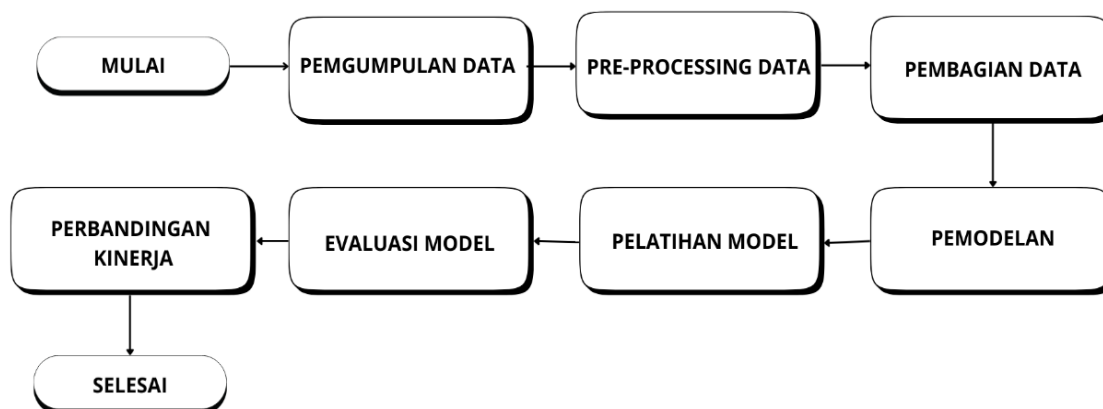
Penelitian Torne et al membandingkan model arsitektur *VGG-16, ResNet50, EfficientNetB0*, dengan dataset 1.129 jenis berbagai patah tulang terdiri 10 kelas peroleh hasil model arsitektur *EfficientNetB0* lebih baik ketiga dibanding Arsitektur *VGG-16* dan *ResNet50*, dengan hasil yang didapatkan 43%[12]. Penelitian lain Ronggo et al perbandingan antar arsitektur *VGG16, VGG19, MobileNet*, dan *InceptionV3* menggunakan dataset 18.160 citra daun tomat dari 9 kelas penyakit. Hasilnya, *MobileNet* mencapai akurasi sebesar 69%[13]. Penelitian terdahulu yang dilakukan Ramadhan et al dan Annur et al terkait klasifikasi tingkat keparahan penyakit *leaf blast* pada tanaman padi menerapkan arsitektur *EfficientNetB0* terhadap 300 citra yang dikategorikan ke dalam 3 kelas, menghasilkan akurasi validasi 90%. Sementara itu, *MobileNetV2* hanya mencapai 78,33%[4],[14]. Perbedaan hasil akurasi tersebut menunjukkan adanya variasi performa antar arsitektur CNN dalam menangani kasus klasifikasi penyakit tanaman.

Penelitian ini bertujuan untuk membandingkan kinerja arsitektur *MobileNetV2* dan *EfficientNetB0* dalam mengklasifikasikan penyakit daun kedelai menggunakan pendekatan transfer learning berbasis deep learning. Meskipun kedua arsitektur telah banyak digunakan pada berbagai tugas klasifikasi citra, kajian yang membandingkan performanya pada klasifikasi penyakit daun kedelai masih terbatas. Oleh karena itu, penelitian ini berkontribusi dalam memberikan analisis komparatif terhadap kedua arsitektur berdasarkan metrik *accuracy, precision, recall*, dan *F1-score*, sehingga dapat menjadi referensi dalam pemilihan model yang sesuai untuk klasifikasi penyakit daun kedelai.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menerapkan pendekatan eksperimental kuantitatif melalui komputasi berbasis *deep learning* untuk mengevaluasi dan membandingkan performa dua arsitektur *Convolutional Neural Network* (CNN), yakni *MobileNetV2* dan *EfficientNetB0*, dalam klasifikasi penyakit daun kedelai berbasis citra digital.



Gambar 1. Flowchart Alur Penelitian

2.1.1 Pengumpulan Data

Dataset citra daun tanaman kedelai untuk penelitian ini bersumber dari platform publik Kaggle <https://www.kaggle.com/datasets>, tepatnya *Soybean Leaf Dataset for Disease Classification* yang dikompilasi oleh Vaishali G. Bhujade <https://www.kaggle.com/datasets/vaishalighujade/soybean-leaf-dataset-for-disease-classification> Walaupun lisensi tidak disebutkan secara eksplisit (*unknown*), pemanfaatan data terbatas pada tujuan akademik semata.

Total jumlah data citra daun kedelai yang dikumpulkan sebanyak 770 citra dengan format JPG. Dari jumlah tersebut, sebanyak 660 citra digunakan dalam penelitian yang terdiri dari 6 kelas dengan masing-masing kelas berjumlah 110 citra. Pembagian jumlah data yang seimbang pada setiap kelas dilakukan untuk mendukung proses pelatihan model yang lebih optimal. Berikut merupakan contoh representatif citra daun kedelai dari setiap kelas yang digunakan dalam penelitian.

Tabel 1. Contoh Sampel Citra Daun Kedelai

No.	Nama Kelas	Sampel
1.	<i>Bacterial Pustule</i> penyakit daun kedelai yang disebabkan oleh bakteri <i>Xanthomonas citri</i> pv. <i>glycines</i> . Gejalanya berupa bercak kuning yang berkembang menjadi pustula pada permukaan daun dan dapat menurunkan produktivitas tanaman.	
2.	<i>Frogeye Leaf Spot</i> penyakit daun kedelai yang disebabkan oleh jamur <i>Cercospora sojina</i> , ditandai dengan bercak cokelat kemerahan pada daun dan dapat menurunkan hasil panen.	
3.	<i>Rust</i> penyakit daun kedelai yang disebabkan oleh jamur <i>Phakopsora pachyrhizi</i> . Penyakit ini ditandai dengan munculnya pustula berwarna oranye hingga cokelat pada daun dan dapat menyebabkan penurunan hasil panen.	
4.	<i>Sudden Death Syndrome</i> penyakit daun kedelai yang disebabkan oleh jamur <i>Corynespora cassiicola</i> . Penyakit ini ditandai dengan bercak cokelat kemerahan berbentuk bulat yang sering membentuk pola cincin konsentris pada daun.	
5.	<i>Target Leaf Spot</i> penyakit kedelai akibat infeksi jamur <i>Fusarium virguliforme</i> yang menyebabkan klorosis, nekrosis, dan kerontokan daun.	
6.	<i>Yellow Mosaic</i> penyakit kedelai akibat infeksi virus begomovirus yang menyebabkan bercak kuning dan pola mosaik pada daun serta dapat menurunkan produktivitas tanaman.	

2.1.2 Pre-processing

Tahap pra-pemrosesan berperan penting dalam mengoptimalkan kualitas model *deep learning* sebelum pelatihan dimulai. Prosesnya meliputi resizing citra ke dimensi 224×224 piksel via Keras, diikuti normalisasi nilai piksel: EfficientNetB0 menskalakan rentang 0–255 menjadi 0–1, sedangkan MobileNetV2 menyesuaikan ke –1 hingga 1. Langkah-langkah ini menstabilkan distribusi data, mempercepat konvergensi, dan meningkatkan akurasi klasifikasi. Tambahan augmentasi data melalui rotasi acak, flip horizontal, mirroring, serta zoom diperkaya untuk variasi dataset pelatihan, sehingga model lebih robust terhadap overfitting dan memiliki generalisasi superior[15].

2.1.3 Pembagian Data

Pada tahap pembagian dataset, 660 citra daun kedelai dibagi menjadi tiga kelompok, pelatihan (80%), validasi (10%), dan pengujian (10%). Bagian pelatihan berfungsi sebagai fondasi bagi model untuk mempelajari pola citra, sementara validasi memantau performa secara real-time dan menunjang tuning parameter. Dataset pengujian, di sisi lain, dievaluasi untuk mengukur kemampuan generalisasi model terhadap data tak dikenal sebelumnya[16].

2.1.4 Pemodelan

Pemodelan dalam penelitian ini menerapkan teknik transfer learning, dengan memanfaatkan bobot pretrained dari ImageNet pada arsitektur MobileNetV2 dan EfficientNetB0. Proses pelatihan menggunakan optimizer Adam dengan learning rate 0,001 pada satu model dan 0,00005 pada model lainnya serta batch size 16. Jumlah epoch dibatasi maksimal 30 untuk menjaga efisiensi waktu, mengingat keterbatasan dataset yang hanya mencakup 660 citra dari enam kelas penyakit. Selain itu, early stopping (patience 7–10) diintegrasikan guna menghentikan pelatihan secara otomatis apabila performa validasi tidak lagi membaik[17].

2.1.5 Pelatihan Model

Tahap ini, dilakukan dua proses inti, yaitu pengembangan dan pelatihan model. Pengembangan model dilakukan dengan pendekatan transfer learning berbasis arsitektur MobileNetV2 dan EfficientNetB0. Selanjutnya, model yang telah di-fine-tuning dikompilasi dan dilatih menggunakan dataset yang telah dipraolah melalui resizing, normalisasi, serta augmentasi pada tahap sebelumnya[18].

2.1.6 Evaluasi Model

Tahap evaluasi bertujuan menilai kinerja *MobileNetV2* dan *EfficientNetB0* dalam mengidentifikasi jenis penyakit daun kedelai pasca-pelatihan. Kedua model diuji pada data pengujian yang terpisah sepenuhnya dari proses pelatihan, memastikan objektivitas hasil yang mencerminkan kemampuan generalisasi. Metrik yang diterapkan mencakup akurasi, presisi, *recall*, serta skor F1.

2.1.7 Perbandingan Kinerja

Tahap perbandingan kinerja dilakukan untuk menilai performa kedua arsitektur yang digunakan, yaitu *MobileNetV2* dan *EfficientNetB0* secara objektif. Setelah masing-masing model menyelesaikan proses pelatihan dan evaluasi, nilai metrik kinerja seperti akurasi, presisi, *recall* dan skor F1 dikumpulkan sebagai landasan perbandingan.

2.2 Arsitektur Model

Penelitian ini menggunakan dua arsitektur deep learning, yaitu *MobileNetV2* dan *EfficientNetB0*, untuk melakukan klasifikasi penyakit daun kedelai. Kedua arsitektur dipilih karena telah banyak digunakan dalam penelitian klasifikasi citra dan menunjukkan kinerja yang baik. Kedua model memanfaatkan metode transfer learning dengan menggunakan bobot awal dari dataset ImageNet, sehingga proses pelatihan dapat dilakukan secara lebih efektif. Penjelasan mengenai arsitektur *MobileNetV2* dan *EfficientNetB0* disajikan pada Subbab 2.2.1 dan 2.2.2.

2.2.1 Arsitektur MobileNetV2

MobileNetV2 merupakan pengembangan dari *MobileNetV1* yang menggunakan teknik *depthwise separable convolution* untuk mengurangi jumlah parameter dan beban komputasi tanpa mengurangi performa model secara signifikan. Arsitektur ini dilengkapi dengan fitur *linear bottleneck* dan *shortcut connection* yang membantu meningkatkan efisiensi pelatihan serta akurasi model. Dalam penelitian ini, *MobileNetV2* digunakan sebagai *pre-trained model* yang telah dilatih pada dataset ImageNet sehingga dapat mempercepat proses pelatihan dan meningkatkan kemampuan klasifikasi citra penyakit daun kedelai [19],[17].

2.2.2 Arsitektur EfficientNetB0

EfficientNetB0 merupakan salah satu varian arsitektur Convolutional Neural Network (CNN) yang dikembangkan dengan pendekatan *compound scaling*, yaitu metode yang menyeimbangkan kedalaman, lebar, dan resolusi jaringan secara proporsional. Arsitektur ini dirancang untuk menghasilkan akurasi yang tinggi dengan jumlah parameter yang relatif sedikit sehingga lebih efisien dalam penggunaan sumber daya komputasi. Dalam penelitian ini, *EfficientNetB0* digunakan sebagai *pre-trained model* yang telah dilatih pada dataset ImageNet untuk mendukung proses klasifikasi penyakit daun kedelai secara lebih efektif [12],[19],[20].

3. HASIL DAN PEMBAHASAN

Hasil dan pembahasan penelitian ini menyajikan uraian mengenai tahapan yang telah dilakukan, mulai dari proses pengolahan data, pelatihan model, hingga evaluasi kinerja model. Setiap tahapan dijelaskan secara sistematis untuk memberikan gambaran yang jelas mengenai alur penelitian serta hasil yang diperoleh. Melalui pembahasan ini, diharapkan dapat diketahui proses yang dilakukan serta kemampuan model dalam menghasilkan kinerja yang optimal.

3.1 Pemodelan dan Pelatihan Spesifikasi

Tahap ini terbagi menjadi dua proses inti. Pertama, pengembangan model melalui *transfer learning* pada arsitektur *MobileNetV2* dan *EfficientNetB0*. Kedua, kompilasi serta pelatihan model pasca-*fine-tuning*, memanfaatkan dataset pra-pemrosesan yang telah di-*resize*, dinormalisasi, dan diaugmentasi.

Rancang untuk lingkungan dengan sumber daya terbatas, *MobileNetV2* menjadi salah satu arsitektur jaringan saraf yang efisien untuk perangkat mobile. Di sisi lain, *EfficientNetB0* menerapkan metode *scaling* yang mengatur kedalaman, lebar, dan resolusi input secara seimbang menggunakan satu parameter utama. Keduanya dikenal memiliki performa yang baik dalam Proses klasifikasi gambar.

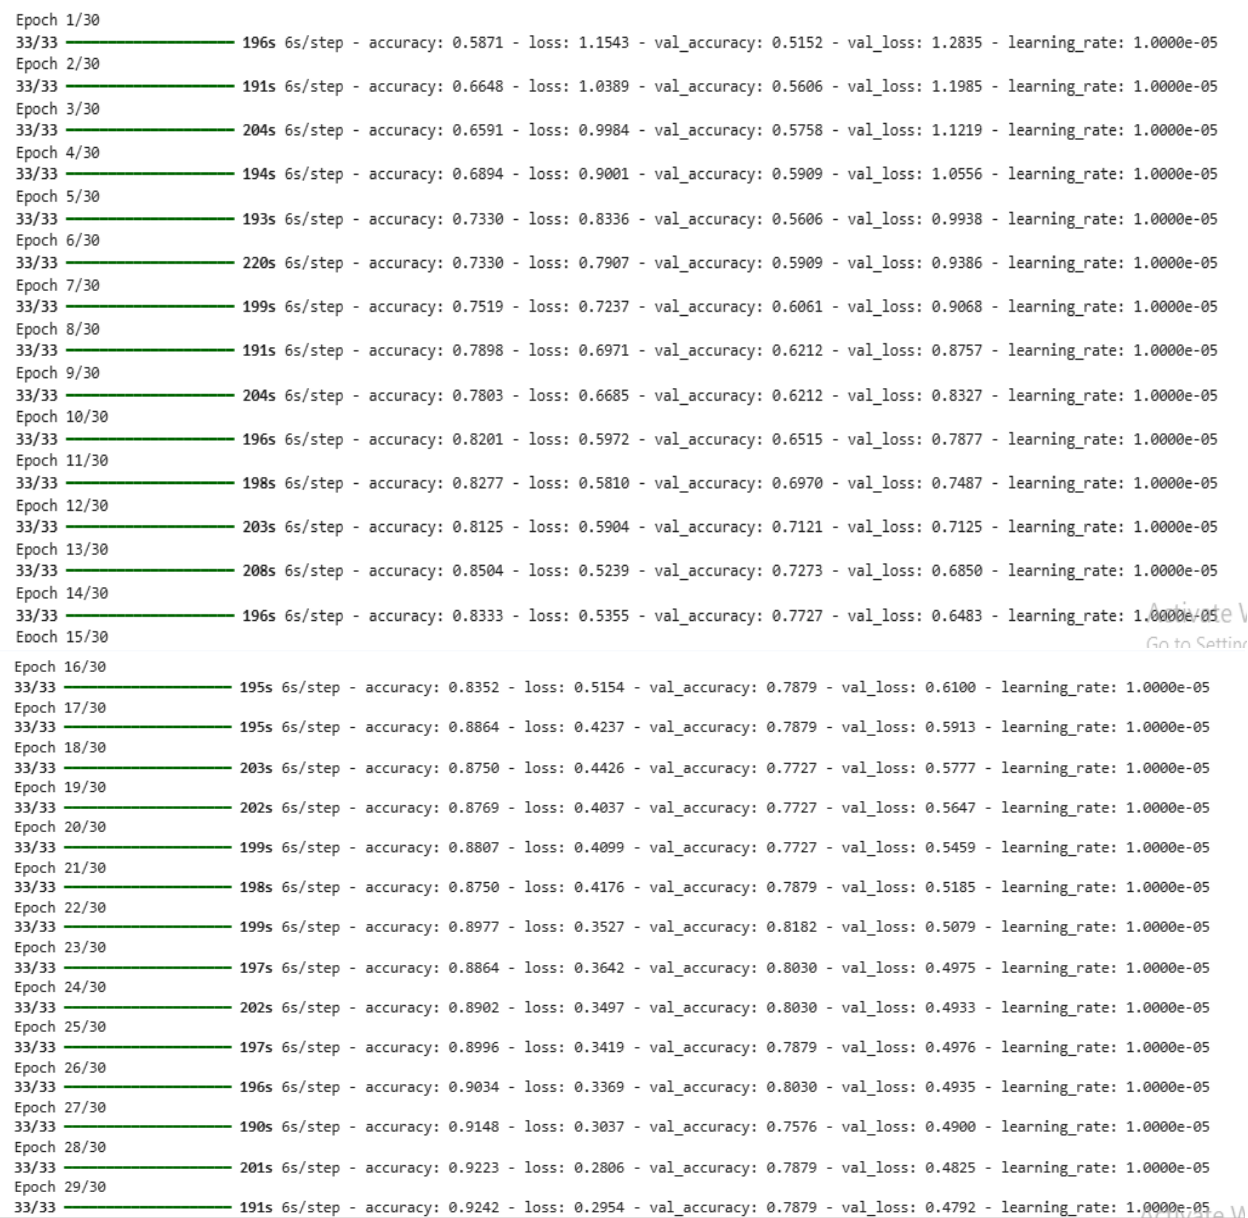
Model dibangun melalui penyusunan beberapa lapisan secara bertahap. Lapisan pertama adalah *GlobalAveragePooling2D* yang dilanjutkan dengan *BatchNormalization*. Setelah itu, digunakan lapisan *Dense* berukuran 128 unit dengan aktivasi *ReLU*, yang juga dipadukan dengan *BatchNormalization*. Struktur ini kembali diterapkan pada lapisan *Dense* berikutnya dengan konfigurasi yang sama. Pada tahap akhir, lapisan output berupa *Dense* digunakan dengan jumlah unit sebanyak enam kelas sesuai kategori daun kedelai, serta menerapkan fungsi aktivasi *softmax*.

3.1.1 Proses Pelatihan Model MobileNetV2 dan EfficientNetBo

Tahap selanjutnya adalah pelatihan model yang bertujuan untuk mempelajari pola dan karakteristik data dari dataset pelatihan. Pada penelitian ini, proses pelatihan dilakukan menggunakan 30 epoch dan *batch size* 16 yang telah

ditentukan berdasarkan hasil pengaturan parameter sebelumnya. Implementasi pelatihan model menggunakan arsitektur MobileNetV2 dan EfficientNetB0 ditunjukkan pada blok program berikut.

Model yang telah dikembangkan selanjutnya dilatih menggunakan dataset pelatihan (*training set*) dan dievaluasi menggunakan dataset validasi (*validation set*) untuk mengukur kemampuan model dalam mengenali pola data serta melakukan generalisasi terhadap data yang belum pernah dilihat sebelumnya. Proses pelatihan dilakukan secara bertahap hingga mencapai kondisi optimal berdasarkan parameter yang telah ditentukan. Hasil keseluruhan proses pelatihan untuk model MobileNetV2 dan EfficientNetB0 divisualisasikan pada gambar berikut.




Gambar 2. Hasil Akhir Pelatihan Model MobileNetV2

Hasil pelatihan yang ditunjukkan pada Gambar 2 menunjukkan bahwa model MobileNetV2 mengalami peningkatan performa yang konsisten selama proses pelatihan. Nilai akurasi pelatihan meningkat dari 58,71% pada epoch pertama menjadi 92,42% pada epoch ke-30, sementara nilai *loss* menurun dari 1,1543 menjadi 0,2954. Pada data validasi, akurasi meningkat dari 51,52% menjadi 78,79%, sedangkan *validation loss* menurun dari 1,2835 menjadi 0,4792. Hasil tersebut menunjukkan bahwa model mampu mempelajari pola data dengan baik dan meningkatkan kemampuan klasifikasinya seiring bertambahnya epoch. Meskipun terdapat perbedaan antara akurasi pelatihan dan akurasi validasi, penurunan *validation loss* yang konsisten mengindikasikan bahwa model masih memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya. Selain itu, penerapan *transfer learning* dan *Early Stopping* membantu menjaga kestabilan proses pelatihan serta mengurangi risiko *overfitting*.

Hasil pelatihan yang ditunjukkan pada Gambar 3 menunjukkan bahwa model EfficientNetB0 mengalami peningkatan performa selama proses pelatihan. Akurasi pelatihan meningkat dari 30,11% pada epoch pertama menjadi

Grafik Akurasi MobileNetV2 Mengilustrasikan akurasi pelatihan dan validasi sepanjang berbagai *epoch*, dengan puncak optimal pada *epoch* ke-30. Perbedaan metrik ini menggambarkan performa model pada data pelatihan (*training accuracy*) versus data tak terlihat (*validation accuracy*). Grafik menunjukkan peningkatan konsisten keduanya tanpa tanda *overfitting*, meskipun akurasi validasi cenderung melebihi pelatihan. Dan Grafik Loss MobileNetV2 memvisualisasikan penurunan training dan validation loss secara bertahap selama pelatihan yang mengonfirmasi absennya *overfitting* pada data pelatihan.



Gambar 5. Visualisasi Perkembangan Grafik Akurasi dan Loss Model EfficientNetB0

Grafik akurasi EfficientNetB0 pelatihan dan validasi divisualisasikan berdasarkan variasi *epoch*, dengan performa prima tercapai pada *epoch* 25. Perbedaan keduanya mencerminkan perbandingan kemampuan model terhadap data yang telah dilihat selama pelatihan (*training accuracy*) dengan dibandingkan pada data yang tidak dilihat selama pelatihan (*validation accuracy*).


Grafik Loss menggambarkan penurunan progresif *training* serta *validation loss* selama pelatihan, yang menandakan stabilitas model bebas *overfitting*. Grafik akurasi model yang tergambar pada visualisasi di atas mengilustrasikan disparitas performa antara fase pelatihan menggunakan data training dan data validasi. Representasi grafik akurasi untuk proses training dengan data training divisualisasikan melalui garis biru, sementara grafik akurasi pada data validasi ditandai dengan garis orange. Analisis dari ketiga grafik tersebut mengungkap tren peningkatan akurasi yang konsisten seiring dengan progresi epoch.

Visualisasi pada gambar tersebut juga menyajikan grafik loss model, yang secara jelas membandingkan performa pelatihan antara data training dan data validasi. Grafik loss untuk data training diwakili oleh garis biru, sedangkan grafik loss pada data validasi ditampilkan juga melalui garis orange. Observasi dari grafik-grafik ini menandakan penurunan nilai loss model yang progresif seiring dengan peningkatan jumlah epoch.

3.2 Evaluasi Model

Tahap evaluasi model menggunakan dataset pengujian berisi 600 sampel, yang tergolong dalam 6 kelas penyakit: *Bacterial Pustula*, *Frogeye Leaf Spot*, *Rust*, *Sudden Death Syndrome*, *Target Leaf Spot*, dan *Yellow Mosaic*. Metrik akurasi, presisi, *recall*, serta F1-score dihitung via *confusion matrix* dan *classification report* dari pustaka Scikit-learn. Implementasi kode pengujian model ditampilkan pada blok program berikut, sementara hasil *confusion matrix* divisualisasikan pada gambar di bawah.

3.2.1 Evaluasi Menggunakan Confusion Matrix



Gambar 6. Confusion Matrix MobileNetV2 dan EfficientNetB0

Matriks Confusion MobileNetV2 membandingkan label sebenarnya dengan label prediksi pada data uji, di mana elemen pada diagonal utama mencerminkan klasifikasi yang benar, sedangkan elemen di luar diagonal menunjukkan kesalahan. Dominasi nilai pada diagonal menggarisbawahi akurasi tinggi model dalam mengklasifikasikan penyakit daun kedelai. Matriks Confusion EfficientNetB0 juga membandingkan label sebenarnya dengan label prediksi, tetapi menampilkan lebih banyak kesalahan klasifikasi di luar diagonal menunjukkan kinerja yang lebih rendah dibandingkan MobileNetV2 dalam membedakan antar kelas.

3.1.2 Classification Report

Hasil evaluasi model, mencakup metrik akurasi, presisi, *recall*, dan F1-score pada MobileNetV2 serta EfficientNetB0, tersaji pada Gambar 7.

=== Classification Report ===					=== Classification Report ===				
	precision	recall	f1-score	support		precision	recall	f1-score	support
Bacterial Pustule	0.85	1.00	0.92	11	Bacterial Pustule	0.64	0.73	0.68	22
Frogeye Leaf Spot	0.85	1.00	0.92	11	Frogeye Leaf Spot	0.94	0.68	0.79	22
Rust	0.71	0.45	0.56	11	Rust	0.46	0.59	0.52	22
Sudden Death Syndrome	1.00	0.73	0.84	11	Sudden Death Syndrome	0.88	0.95	0.91	22
Target Leaf Spot	0.73	0.73	0.73	11	Target Leaf Spot	0.42	0.36	0.39	22
Yellow Mosaic	0.79	1.00	0.88	11	Yellow Mosaic	1.00	0.91	0.95	22
accuracy			0.82	66	accuracy			0.70	132
macro avg	0.82	0.82	0.81	66	macro avg	0.72	0.70	0.71	132
weighted avg	0.82	0.82	0.81	66	weighted avg	0.72	0.70	0.71	132
=== Hasil Evaluasi ===					=== Hasil Evaluasi ===				
Accuracy :	0.8182				Accuracy :	0.7045			
Precision:	0.8199				Precision:	0.723			
Recall :	0.8182				Recall :	0.7045			
F1-Score :	0.8064				F1-Score :	0.7077			
MSE :	1.0606				MSE :	1.9545			
RMSE :	1.0299				RMSE :	1.3981			

Gambar 7. Hasil *Classification Report* dengan Metrix Evaluasi Model *MobileNetV2* dan *EfficientNetB0*

Classification report MobileNetV2 menunjukkan bahwa model memperoleh akurasi sebesar 81,82% dengan nilai presisi, *recall*, dan *F1-score* rata-rata sekitar 0,82. Performa model tergolong baik pada sebagian besar kelas, khususnya pada kelas *Bacterial Pustule*, *Frogeye Leaf Spot*, dan *Yellow Mosaic* yang memiliki nilai *recall* tinggi. Namun, pada kelas *Rust* nilai *recall* masih relatif rendah, yang menunjukkan masih adanya kesalahan klasifikasi pada kelas tersebut. Secara keseluruhan, model telah menunjukkan kinerja yang baik dalam mengklasifikasikan data, meskipun masih diperlukan peningkatan pada beberapa kelas tertentu.

Classification report EfficientNetB0 menunjukkan bahwa model memperoleh akurasi sebesar 70,45% dengan nilai presisi, *recall*, dan *F1-score* rata-rata sekitar 0,71. Performa model bervariasi pada setiap kelas, di mana kelas *Yellow Mosaic* memiliki hasil terbaik, sedangkan beberapa kelas lain seperti *Rust* dan *Target Leaf Spot* masih menunjukkan performa yang lebih rendah. Secara keseluruhan, model sudah mampu melakukan klasifikasi dengan cukup baik.

3.3 Perbandingan Kinerja

Perbandingan antar model bertujuan untuk mengidentifikasi arsitektur yang lebih unggul MobileNetV2 atau EfficientNetB0 dalam klasifikasi penyakit daun kedelai, berdasarkan metrik pelatihan dan evaluasi seperti *akurasi*, *presisi*, *recall*, dan *F1-score*.

Tabel 2. Tabel Nilai *Akurasi*, *Presisi*, *Recall*, dan *F-1 Score* dari Model *MobileNetV2* dan *EfficientNetB0*

No	Arsitektur	Accuracy	Precision	Recall	F-1 Score
1.	MobileNetV2	0,818	0,8199	0,8182	0,8064
2.	EfficientNetB0	0,704	0,723	0,7045	0,7077

Perbandingan metrik evaluasi pada tabel menunjukkan superioritas model MobileNetV2 dibandingkan EfficientNetB0 dalam tugas klasifikasi citra daun tanaman kedelai. MobileNetV2 mencapai accuracy sebesar 81.8%, precision 81.99%, recall 81.82%, serta F1-score 80.64%, yang mengindikasikan kemampuan model dalam memprediksi label benar secara akurat dan seimbang antar kelas. Sebaliknya, EfficientNetB0 hanya meraih accuracy 70.4%, precision 72.3%, recall 70.45%, dan F1-score 70.77%, mencerminkan tingkat kesalahan klasifikasi yang lebih tinggi serta ketidakseimbangan dalam mendeteksi berbagai penyakit daun.

3.4 Pembahasan

Hasil penelitian menunjukkan bahwa MobileNetV2 memperoleh akurasi sebesar 81%, sedangkan EfficientNetB0 memperoleh akurasi sebesar 70% dalam klasifikasi penyakit daun kedelai. Hasil tersebut menunjukkan bahwa

MobileNetV2 memiliki performa yang lebih baik dibandingkan EfficientNetB0 pada dataset yang digunakan. Jika dibandingkan dengan penelitian terdahulu, Penelitian Annur at all, MobileNetV2 pada klasifikasi tingkat keparahan penyakit *Leaf Blast* tanaman padi memperoleh akurasi rata-rata sebesar 78%[4]. Pada penelitian klasifikasi empat tanaman obat mencapai akurasi sebesar 99%[21]. Penelitian Marpaung at all, Klasifikasi Kesehatan Daun Tomat menggunakan VGG memperoleh akurasi sebesar 93%, InceptionV3 mencapai akurasi sebesar 98%, sementara MobileNet mencapai akurasi 88%[13]. Pada penelitian Upadhyay at all, deteksi penyakit pada kentang memperoleh akurasi validasi sebesar 99% EfficientNetB0 dan ResNet50V2 mencapai akurasi 90%[10].

Perbedaan hasil tersebut dapat dipengaruhi oleh karakteristik dataset, jumlah kelas, variasi citra, teknik *preprocessing*, serta konfigurasi parameter pelatihan yang digunakan pada masing-masing penelitian. Pada penelitian ini, objek yang diklasifikasikan terdiri dari enam kelas penyakit daun kedelai yang memiliki gejala visual yang relatif mirip, sehingga meningkatkan tingkat kesulitan klasifikasi. Kondisi tersebut dapat menyebabkan performa model lebih rendah dibandingkan penelitian lain yang menggunakan jumlah kelas lebih sedikit atau memiliki perbedaan karakteristik visual yang lebih jelas antar kelas. Meskipun demikian, hasil penelitian ini menunjukkan bahwa MobileNetV2 lebih efektif dibandingkan EfficientNetB0 dalam mengklasifikasikan penyakit daun kedelai pada dataset yang digunakan.

4. KESIMPULAN

Penelitian ini menyimpulkan bahwa model MobileNetV2 merupakan pilihan unggul untuk klasifikasi penyakit daun tanaman kedelai, dengan metrik evaluasi superior seperti akurasi 81.8%, precision 81.99%, recall 81.82%, dan F1-score 80.64% pada dataset pengujian 1.000 sampel dari 10 kelas. Hal ini didukung oleh grafik training yang stabil (akurasi meningkat, loss menurun), confusion matrix dengan dominasi diagonal utama, serta classification report yang menunjukkan ketepatan tinggi antar kelas. Performa ini menegaskan efektivitas arsitektur ringan MobileNetV2 dalam menangani citra daun tanaman secara akurat dan efisien. EfficientNetB0 menampilkan keterbatasan dengan akurasi hanya 70.4% dan kesalahan klasifikasi yang lebih nyata pada confusion matrix, meskipun menunjukkan tren perbaikan selama training. Kesimpulan keseluruhan menekankan bahwa MobileNetV2 lebih siap untuk implementasi praktis dalam sistem deteksi penyakit tanaman, sementara EfficientNetB0 berpotensi ditingkatkan untuk aplikasi masa depan, sehingga berkontribusi pada pertanian presisi yang lebih baik. Penelitian selanjutnya disarankan untuk menggunakan jumlah dataset yang lebih banyak serta melakukan pengembangan pada tahap *preprocessing* dan penyesuaian parameter pelatihan agar performa model dapat meningkat. Selain itu, penelitian berikutnya juga dapat mencoba arsitektur *deep learning* lainnya untuk memperoleh hasil klasifikasi yang lebih optimal pada penyakit daun tanaman kedelai.

REFERENCES

- [1] Soesanto Loekes, *Kompendium Penyakit-Penyakit Tanaman Kedelai*. Jakarta, Indonesia: Bumi Aksara, 2022.
- [2] Agussabti, Rahmaddiansyah, Romano, and T. A. Awaina, "Farmer's Unwillingness to Grow Soybean," *IOP Conf. Ser. Earth Environ. Sci.*, vol. 425, no. 1, 2020, doi: 10.1088/1755-1315/425/1/012022.
- [3] E. Nurmindia, D. Mandalika, and C. Ayu, "Evaluasi Kinerja Ekonomi Usahatani Kedelai Di Kecamatan Batulayar Kabupaten Lombok Barat," *Jasintek*, vol. 4, no. 2, pp. 115–123, 2023, doi: 10.52232/jasintek.v4.i2.156.
- [4] I. F. Annur, J. Umami, M. N. Annafii, N. Trisnaningrum, and O. V. Putra, "Klasifikasi Tingkat Keparahan Penyakit Leafblast Tanaman Padi Menggunakan MobileNetv2," *Fountain Informatics J.*, vol. 8, no. 1, pp. 7–14, 2023, doi: 10.21111/fij.v8i1.9419.
- [5] Kuwat Setiyanto and Michael Bolang, "Analisis Perbandingan Hasil Klasifikasi Jenis Penyakit Tanaman Tomat Menggunakan Arsitektur Mobilenet, Densenet121, Dan Xception," *J. Tek. dan Sci.*, vol. 3, no. 3, pp. 56–69, 2024, doi: 10.56127/jts.v3i3.1898.
- [6] Z. Li, W. Tao, J. Liu, F. Zhu, G. Du, and G. Ji, "Tomato Leaf Disease Recognition via Optimizing Deep Learning Methods Considering Global Pixel Value Distribution," *Horticulturae*, vol. 9, no. 9, pp. 1–15, 2023, doi: 10.3390/horticulturae9091034.
- [7] F. Zaelani and Y. Miftahuddin, "Perbandingan Metode EfficientNetB3 dan MobileNetV2 Untuk Identifikasi Jenis Buah-buahan Menggunakan Fitur Daun," *J. Ilm. Teknol. Infomasi Terap.*, vol. 9, no. 1, pp. 1–11, 2022, doi: 10.33197/jitter.vol9.iss1.2022.911.
- [8] I. Mudzakir and T. Arifin, "Klasifikasi Penggunaan Masker dengan Convolutional Neural Network Menggunakan Arsitektur MobileNetv2," *Expert J. Manaj. Sist. Inf. dan Teknol.*, vol. 12, no. 1, p. 76, 2022, doi: 10.36448/expert.v12i1.2466.
- [9] F. A. Hariz, I. N. Yulita, and I. Suryana, "Human Activity Recognition Berdasarkan Tangkapan Webcam Menggunakan Metode Convolutional Neural Network (CNN) Dengan Arsitektur MobileNet," *JITSI J. Ilm. Teknol. Sist. Inf.*, vol. 3, no. 4, pp. 103–115, 2022, doi: 10.62527/jitsi.3.4.97.
- [10] S. K. Upadhyay, J. Jain, and R. Prasad, "Early Blight and Late Blight Disease Detection in Potato Using Efficientnetb0," *Int. J. Exp. Res. Rev.*, vol. 38, pp. 15–25, 2024, doi: 10.52756/ijerr.2024.v38.002.
- [11] F. Marpaung, N. Khairina, and R. Muliono, "Klasifikasi Daun Teh Siap Panen Menggunakan Convolution Neural Network Arsitektur MobileNetV2," *J. Teknoinfo*, vol. 18, no. 1, pp. 215–225, 2024, doi: 10.33365/jti.v18i1.3435.
- [12] M. Rybczak and K. Kozakiewicz, "Deep Machine Learning of MobileNet, Efficient, and Inception Models," *Algorithms*, vol. 17, no. 3, 2024, doi: 10.3390/a17030096.
- [13] R. Ronggo, B. Pratomo, and P. Palupingsih, "Analisis Perbandingan Performa Model Klasifikasi Kesehatan Daun Tomat menggunakan Arsitektur VGG, MobileNet, dan Inception V3 Analysis Tomato Leaf Health Classification Model"



- Performance Comparison Using VGG , MobileNet , and Inception V3,” *J. Ilmu Komput. dan Agri Inform.*, vol. 10, no. 1, pp. 98–110, 2023, doi: 10.29244/jika.10.1.98-110.
- [14] E. Ramadhan, S. Akbar, M. F. Al-farizi, T. Agustin, and P. Informatika, “Klasifikasi Tingkat Keparahan Penyakit Leaf Blast Pada Tanaman Padi Menggunakan Efficientnetb0 Menggunakan,” *Fountain Informatics J.*, vol. 8, no. 1, pp. 429–440, 2024, doi: 10.21111/fij.v8i1.9419.
- [15] W. Zhu, L. Xie, J. Han, and X. Guo, “The Application Of Deep Learning in Cancer Prognosis Prediction,” *Cancers (Basel)*, vol. 12, no. 3, pp. 1–19, 2020, doi: 10.3390/cancers12030603.
- [16] X. Liu, L. Song, S. Liu, and Y. Zhang, “A Review of Deep-Learning-Based Medical Image Segmentation Methods,” *Sustain.*, vol. 13, no. 3, pp. 1–29, 2021, doi: 10.3390/su13031224.
- [17] D. H. Putra, S. Sulistyowati, and V. Yudisthiana, “Perbandingan Tingkat Akurasi Arsitektur Convolutionsl Neural Network untuk Model Deteksi Penggunaan Masker secara Otomatis,” *J. Ilmu Pengetah. dan Teknol.*, vol. 7, no. 1, pp. 25–32, 2023, doi: 10.31543/jii.v7i1.228.
- [18] J. Naranjo-Torres, M. Mora, R. Hernández-García, R. J. Barrientos, C. Fredes, and A. Valenzuela, “A Review of Convolutional Neural Network Applied to Fruit Image Processing,” *Appl. Sci.*, vol. 10, no. 10, 2020, doi: 10.3390/app10103443.
- [19] S. Nigam, R. Jain, V. K. Singh, S. Marwaha, A. Arora, and S. Jain, “EfficientNet Architecture and Attention Mechanism-Based Wheat Disease Identification Model,” *Procedia Comput. Sci.*, vol. 235, pp. 383–393, 2024, doi: 10.1016/j.procs.2024.04.038.
- [20] M. Ucan, B. Kaya, O. Aygun, M. Kaya, and R. Alhadj, “Comparison of EfficientNet CNN Models for Multi-Label Chest X-ray Disease Diagnosis,” *PeerJ Comput. Sci.*, vol. 11, p. e2968, 2025, doi: 10.7717/peerj-cs.2968.
- [21] D. D. Parsaulian, N. Nainggolan, W. W. Kalengkonga, and E. Ketaren, “Klasifikasi Empat Tanaman Obat Menggunakan Arsitektur Mobilenetv2,” *J. TIMES*, vol. 13, no. 2, pp. 135–141, 2024, doi: 10.51351/jtm.13.2.2024780.