



KLASIFIKASI PENYAKIT DAUN SINGKONG MENGGUNAKAN ARSITEKTUR EFFICIENTNET BERBASIS TRANSFER LEARNING

Syahrul Ramadani¹, Muh. Rasyid Ridha², Samsudin³

Email: ¹syahrulgeal363@gmail.com, ²rasyid4sky@gmail.com, ³samsudinsadek@gmail.com

¹ Sistem Informasi, Fakultas teknik dan ilmu komputer, Universitas Islam Indragiri

Diterima: 22 April 2026 | Direvisi: 27 April 2026 | Disetujui: 27 April 2026

©2020 Program Studi Teknik Informatika Fakultas Ilmu Komputer,
Universitas Muhammadiyah Riau, Indonesia

Abstrak

Tanaman singkong (*Manihot esculenta*) merupakan komoditas strategis yang produktivitasnya sering terancam oleh penyakit daun seperti hawar bakteri, garis cokelat, bercak daun, dan mosaik. Identifikasi manual oleh manusia cenderung subjektif, memakan waktu, dan rentan kesalahan. Penelitian ini bertujuan mengembangkan sistem klasifikasi penyakit daun singkong otomatis berbasis *Deep Learning* yang akurat dan efisien. Untuk mengatasi beban komputasi model konvensional serta tantangan data lapangan seperti ketidakseimbangan kelas dan variasi pencahayaan, penelitian ini mengusulkan arsitektur *EfficientNet* dengan metode *Transfer Learning*. Model memanfaatkan bobot *pre-trained* dari *ImageNet* untuk mempercepat *konvergensi* dan mengoptimalkan ekstraksi fitur visual. Hasil pengujian pada dataset citra daun singkong menunjukkan bahwa model berhasil mencapai tingkat akurasi sebesar 81%. Pencapaian ini membuktikan bahwa penggunaan *EfficientNet* mampu memberikan prediksi yang objektif dengan efisiensi komputasi yang tinggi. Temuan ini berpotensi besar untuk diimplementasikan ke dalam perangkat portabel sebagai alat deteksi dini bagi petani, guna mendukung tindakan mitigasi yang cepat dan menjaga stabilitas ketahanan pangan global.

Kata kunci: Singkong, Penyakit Daun, *Deep Learning*, *EfficientNet*, *Transfer Learning*, Klasifikasi Citra.

CLASSIFICATION OF LEAF DISEASES USING THE EFFICIENTNET ARCHITECTURE BASED ON TRANSFER LEARNING

Abstract

Cassava (Manihot esculenta) is a strategic agricultural commodity whose productivity is frequently threatened by leaf diseases such as bacterial blight, brown streak, green mottle, and mosaic disease. Manual identification by humans tends to be subjective, time-consuming, and prone to error. This study aims to develop an automatic and intelligent Cassava leaf disease classification system based on Deep Learning that is both accurate and efficient. To overcome the computational burden of conventional models and address real-world data challenges, such as class imbalance and lighting variations, this research proposes the use of the EfficientNet architecture combined with the Transfer Learning method. The model utilizes pre-trained weights from ImageNet to accelerate convergence and optimize visual feature extraction. Experimental results on the Cassava leaf image dataset show that the proposed model successfully achieved an accuracy rate of 81%. These findings demonstrate that the EfficientNet approach provides objective predictions with high computational efficiency. This research has significant potential for implementation in portable devices as an early detection tool for farmers, supporting rapid mitigation actions and maintaining global food security stability.

Keywords: *Cassava, Leaf Disease, Deep Learning, EfficientNet, Transfer Learning, Image Classification.*

1. PENDAHULUAN

Tanaman singkong (*Manihot esculenta*) merupakan salah satu komoditas pertanian strategis yang memiliki peran krusial dalam menjaga ketahanan pangan global, khususnya di negara-negara beriklim tropis seperti Indonesia. Selain umbinya yang menjadi sumber karbohidrat utama, daun singkong juga dimanfaatkan secara luas oleh masyarakat sebagai sayuran bernilai gizi tinggi. Daun pada tanaman singkong memiliki fungsi vital sebagai tempat berlangsungnya proses fotosintesis yang secara langsung memengaruhi pertumbuhan dan hasil panen umbi [1]. Sayangnya, produktivitas komoditas ini kerap terancam oleh berbagai jenis penyakit tanaman, seperti hawar bakteri (*bacterial blight*), penyakit garis cokelat (*brown streak disease*), bercak daun (*green mottle*), hingga penyakit mosaik (*mosaic disease*), yang dapat menyebabkan kerusakan fisik pada daun, gagal panen, dan kerugian ekonomi yang signifikan bagi para petani [2].

Dalam upaya memitigasi penyebaran penyakit tersebut, deteksi dini yang cepat dan akurat sangat diperlukan. Secara tradisional, identifikasi penyakit daun singkong dilakukan melalui pengamatan visual oleh ahli pertanian, yang sering kali memakan waktu, bersifat subjektif, dan rentan terhadap kesalahan (*human error*) [3]. Oleh karena itu, pendekatan komputasi modern menggunakan kecerdasan buatan (*Artificial Intelligence*), khususnya *Machine Learning* dan *Deep Learning*, telah menjadi solusi inovatif yang banyak diadopsi dalam *smart agriculture*. *Deep Learning*, melalui arsitektur *Convolutional Neural Network (CNN)*, terbukti memiliki kemampuan yang luar biasa dalam mengekstraksi fitur visual yang kompleks dari citra digital, sehingga memungkinkan sistem untuk mengklasifikasikan jenis penyakit tanaman secara otomatis berdasarkan pola-pola bercak, perubahan warna, dan tekstur spesifik pada permukaan daun [4].


Sejumlah penelitian terdahulu telah berupaya mengimplementasikan pendekatan *Deep Learning* untuk klasifikasi penyakit tanaman. Beberapa studi menggunakan model *CNN* klasik seperti *VGG16*, *Inception*, dan *ResNet* untuk mendeteksi penyakit pada citra daun [5]. Meskipun penelitian-penelitian tersebut berhasil mencapai tingkat akurasi yang memadai, sebagian besar model yang digunakan memiliki kelemahan berupa jumlah parameter yang sangat besar sehingga membutuhkan sumber daya komputasi yang tinggi. Selain itu, beberapa penelitian sebelumnya sering kali dilatih menggunakan dataset dengan kondisi laboratorium yang ideal, sehingga performa model cenderung menurun drastis ketika dihadapkan pada citra lapangan (*real-world data*) yang memiliki gangguan (*noise*), ketidakseimbangan jumlah kelas (*class imbalance*), serta variasi pencahayaan dan sudut pengambilan gambar [6].

Untuk mengatasi keterbatasan komputasi dan mengoptimalkan ekstraksi fitur visual, penelitian ini mengusulkan penggunaan arsitektur model *EfficientNet* yang dikombinasikan dengan metode *Transfer Learning*. *EfficientNet* merancang ulang skala jaringan *Deep Learning* melalui metode *Compound Scaling*, yang secara matematis menyeimbangkan kedalaman, lebar, dan resolusi jaringan untuk mencapai tingkat akurasi maksimal dengan jumlah parameter yang jauh lebih ringan dibandingkan model *CNN* konvensional [7]. Penerapan *Transfer Learning* dalam studi ini memungkinkan model untuk memanfaatkan bobot (*weights*) yang telah dilatih sebelumnya pada dataset berskala raksasa (*ImageNet*). Hal ini tidak hanya mempercepat proses *konvergensi* saat pelatihan, tetapi juga secara signifikan meningkatkan kemampuan generalisasi model dalam mengidentifikasi pola penyakit spesifik pada daun singkong tanpa harus melatih jaringan dari awal [8].

Berdasarkan latar belakang dan evaluasi terhadap penelitian-penelitian sebelumnya, penelitian ini dilakukan dengan tujuan utama untuk mengembangkan sistem klasifikasi penyakit daun singkong yang tidak hanya akurat, tetapi juga efisien secara komputasi dan tangguh terhadap tantangan data di lapangan. Alasan mendasar dilaksanakannya penelitian ini adalah untuk menjembatani kesenjangan antara kecanggihan teknologi *Computer Vision* dengan kebutuhan praktis petani di sektor pertanian. Dengan mengintegrasikan teknik penanganan ketidakseimbangan data dan augmentasi citra yang komprehensif, diharapkan model ini mampu memberikan hasil prediksi yang objektif. Pada akhirnya, luaran penelitian ini diharapkan dapat menjadi landasan bagi pengembangan aplikasi deteksi dini penyakit tanaman yang portabel dan ramah guna, sehingga dapat secara langsung membantu petani dalam mengambil tindakan penanganan yang tepat waktu dan menjaga stabilitas panen singkong [9].

2. METODE PENELITIAN

Dalam penelitian ini, proses klasifikasi penyakit daun singkong terdiri dari beberapa tahapan seperti yang ditunjukkan pada Gambar 1.



Gambar 1 Kerangka Penelitian

Pada Gambar 1 menunjukkan kerangka penelitian ini mengikuti tahapan sistematis *Machine Learning* yang dimulai dari persiapan data hingga perolehan hasil klasifikasi akhir. Proses diawali dengan Pengumpulan Data menggunakan dataset citra daun singkong dari *Kaggle* yang mencakup lima kategori kondisi kesehatan tanaman, yang kemudian dilanjutkan dengan Pembagian Data menggunakan rasio 80% untuk data latih dan 20% untuk data validasi guna menjamin keandalan pengujian model. Tahap krusial berikutnya adalah Pra-pemrosesan dan Augmentasi Citra yang bertujuan untuk menormalisasi data dan memperkaya variasi visual melalui teknik seperti rotasi dan flip, disusul dengan Penanganan *Imbalance Data* menggunakan *Weighted Random Sampler* untuk memastikan model tidak bias terhadap kelas mayoritas. Selanjutnya, pada tahap Perancangan Model, diterapkan metode *Transfer Learning* dengan arsitektur *EfficientNet-B0* yang telah dimodifikasi pada bagian *classifier*-nya. Seluruh komponen ini diintegrasikan dalam tahap Pelatihan Model menggunakan *optimizer AdamW* dan *Cosine Annealing LR* untuk mencapai *konvergensi* yang optimal. Alur ini diakhiri dengan Evaluasi Model melalui analisis grafik performa, hingga menghasilkan Model Klasifikasi final yang memiliki kemampuan deteksi penyakit daun singkong dengan tingkat akurasi sebesar 81%.

2.1 Pengumpulan data

Dataset citra daun tanaman singkong yang digunakan pada penelitian ini diambil dari repositori publik *Kaggle*. Total citra yang digunakan pada penelitian ini yaitu sebanyak 21.397 citra. Berikutnya, dataset tersebut dibagi dengan rasio 80:20. Pembagian secara acak ini menghasilkan 17.117 citra untuk train data dan 4.280 citra untuk *validation data*, yang mana train data digunakan untuk melatih model dan *validation data* digunakan untuk melakukan evaluasi kinerja model yang sedang dibangun. Berikut merupakan sampel citra daun singkong pada setiap kelas. Sampel dataset penyakit daun singkong dapat dilihat pada Gambar 2.



Gambar 2 sampel citra penyakit daun singkong

Gambar 2 merupakan sampel citra penyakit daun singkong yang terdiri dari kelas *bacterial blight*, kelas *brown streak disease*, kelas *green mottle*, kelas *Healthy*, dan kelas *mosaic disease*.

2.2 Preprocessing data & augmentasi

Sebelum data dibagi kedalam data training, validasi, dan *testing*, citra daun singkong terlebih dahulu melewati tahap *preprocessing* dataset. Tahapan awal ini sangat penting untuk memastikan kualitas citra yang lebih optimal serta menyesuaikan format data agar dapat diproses oleh arsitektur *Deep Learning*. Berikut langkah-langkah *preprocessing* dataset yang diuraikan dalam penelitian ini:

1. Penyesuaian Ukuran Citra (*Resizing*)

Dataset asli memiliki resolusi citra yang bervariasi. Oleh karena itu, seluruh citra diseragamkan ukurannya (*Resizing*) menjadi dimensi 224 x 224 piksel. Penyeragaman ini merupakan syarat wajib untuk menyesuaikan standar ukuran masukan (*input shape*) pada arsitektur *EfficientNet_B0*. Selain itu, pengecilan dimensi citra ini juga berfungsi untuk mengurangi beban komputasi dan mempercepat waktu pelatihan model.

2. Augmentasi Data (*Data Augmentation*)

Untuk mencegah model dari masalah *overfitting* (terlalu menghafal data latih) dan meningkatkan kemampuan generalisasinya terhadap data baru, diterapkan serangkaian teknik augmentasi spasial dan warna. Transformasi ini menyimulasikan berbagai kondisi pengambilan gambar di lahan pertanian nyata. Adapun teknik augmentasi yang digunakan meliputi:

- a. Pembalikan Acak (*Random Vertical/Horizontal Flip*): Membalikkan orientasi citra secara vertikal maupun horizontal untuk melatih model mengenali penyakit dari berbagai sudut pandang.
- b. Penyesuaian Warna (*Color Jitter*): Mengubah tingkat kecerahan (*brightness*), kontras (*contrast*), dan saturasi (*saturation*) secara acak untuk mengatasi variasi intensitas cahaya matahari saat pengambilan foto di lapangan.
- c. Perubahan Perspektif (*Random Perspective*): Mendistorsi citra secara acak untuk menyimulasikan kemiringan sudut kamera terhadap permukaan daun singkong.

3. Konversi Tensor dan Normalisasi (*Normalization*)

Citra digital yang masih berupa susunan matriks piksel (skala 0-255) dikonversi menjadi format Tensor agar dapat dihitung secara matematis oleh kerangka kerja (seperti *PyTorch/TensorFlow*). Selanjutnya, dilakukan proses normalisasi nilai piksel menggunakan nilai rata-rata (*mean*) dan simpangan baku (*standard deviation*) standar dari dataset *ImageNet*. Normalisasi ini krusial untuk menyelaraskan distribusi rentang nilai data, sehingga mempercepat proses *konvergensi* saat menerapkan metode *Transfer Learning*.

2.3 Pembagian data

Dataset citra daun singkong dalam penelitian ini dibagi menjadi dua bagian utama, yaitu data latih (*training data*) dan data validasi (*validation data*) dengan rasio 80:20. Dari total 21.397 citra, sebanyak 17.117 citra dialokasikan sebagai data latih dan 4.280 citra sebagai data validasi. Pembagian dilakukan secara acak (*random split*) untuk menjamin keberagaman variasi data pada setiap bagian.

Data latih digunakan sepenuhnya oleh arsitektur *Deep Learning* untuk mempelajari pola fitur visual penyakit dan memperbarui bobot parameter jaringan secara iteratif. Sebaliknya, data validasi berfungsi sebagai himpunan data independen untuk mengukur kemampuan generalisasi model pada setiap *epoch*. Melalui data validasi, pergerakan nilai akurasi dan loss dapat dipantau secara ketat sebagai indikator utama untuk mencegah fenomena *overfitting*, sehingga model tidak sekadar menghafal data latih tetapi mampu mengklasifikasikan data baru dengan akurat.

2.4 Pemodelan Arsitektur *EfficientNet* & *Transfer Learning*

Pembangunan model klasifikasi penyakit daun singkong dalam penelitian ini mengadopsi arsitektur *EfficientNet-B0* yang diintegrasikan dengan pendekatan *Transfer Learning*. Arsitektur ini dipilih karena kemampuannya dalam mengoptimalkan ekstraksi fitur melalui metode *Compound Scaling*, yang menyeimbangkan kedalaman, lebar, dan resolusi jaringan secara efisien namun tetap memiliki beban komputasi yang rendah. Untuk mempercepat pencapaian titik *konvergensi*, model memanfaatkan inisialisasi bobot (*pre-trained weights*) dari dataset *ImageNet*.

Penyesuaian spesifik dilakukan pada bagian *classifier head*, di mana lapisan prediksi bawaan diganti dengan lapisan *Fully Connected* baru yang memiliki lima *neuron* keluaran sesuai dengan kategori kelas penyakit daun singkong. Sebagai langkah optimasi, teknik regularisasi *Dropout* juga diterapkan pada lapisan tersebut untuk meminimalkan kompleksitas model sekaligus mencegah risiko terjadinya *overfitting* selama proses pembelajaran fitur [9].

2.5 Pelatihan model

Pelatihan model dilakukan menggunakan 17.117 citra latih untuk mengekstraksi fitur penyakit dan memperbarui bobot jaringan secara iteratif. Arsitektur model dioptimasi dengan algoritma *Adam* pada *learning rate* 0,001 guna mencapai *konvergensi* yang efisien. Selisih antara prediksi dan label asli diukur menggunakan fungsi kerugian *Sparse Categorical Crossentropy*, yang efektif untuk klasifikasi multikelas. Data diproses dalam *batch size* sebesar 32 untuk menjaga stabilitas memori dan optimalisasi gradien. Performa jaringan dievaluasi secara kontinu pada setiap akhir *epoch* menggunakan 4.280 citra validasi independen. Langkah ini dilakukan untuk memantau pergerakan nilai akurasi serta *loss* sebagai upaya preventif dalam menghindari fenomena *overfitting*.

2.6 Evaluasi model

Tahap akhir penelitian melibatkan evaluasi kinerja model menggunakan metrik klasifikasi untuk mendapatkan gambaran performa yang objektif. Metrik yang digunakan meliputi Akurasi (total prediksi benar), *Presisi* (ketepatan prediksi positif), *Recall* (kemampuan identifikasi kelas positif), dan *F1-Score* (keseimbangan rata-rata *Presisi* dan *Recall*). Selain itu, *Confusion matrix* digunakan untuk memvisualisasikan distribusi prediksi dan menganalisis kesalahan klasifikasi pada setiap kelas secara detail.

3. HASIL DAN PEMBAHASAN

3.1. Pengumpulan dataset

Data yang digunakan dalam penelitian ini adalah data sekunder yang diambil dari situs web www.kaggle.com. Kaggle merupakan platform yang menyediakan berbagai dataset untuk keperluan *Machine Learning* dan *Deep Learning*. Dataset tersebut berisi citra daun singkong dengan berbagai kondisi penyakit yang diambil langsung dari lahan pertanian. Secara keseluruhan, terdapat 21.397 citra yang terbagi ke dalam 5 kategori penyakit, yaitu *Cassava Bacterial blight (CBB)*, *Cassava Brown streak disease (CBSD)*, *Cassava Green mottle (CGM)*, *Cassava Mosaic disease (CMD)*, dan satu kategori untuk daun yang sehat (*Healthy*). Berdasarkan observasi data, ditemukan adanya ketidakseimbangan jumlah data (*class imbalance*) yang cukup signifikan, di mana kategori *Cassava Mosaic disease (CMD)* memiliki jumlah citra terbanyak mencapai 10.882 gambar, sementara kategori lainnya memiliki jumlah yang jauh lebih sedikit. Pembagian data latih dan data validasi secara rinci telah dipaparkan pada Tabel 1.


Tabel 1 Dataset

No.	Kelas Penyakit	Train Data (80%)	Validation data (20%)	Total
1	<i>Cassava Bacterial blight (CBB)</i>	869	218	1.087
2	<i>Cassava Brown streak disease (CBSD)</i>	1.751	438	2.189
3	<i>Cassava Green mottle (CGM)</i>	1.909	478	2.387
4	<i>Cassava Mosaic disease (CMD)</i>	8.705	2.177	10.882
5	<i>Healthy (Sehat)</i>	2.533	634	3.167
	Total	17.117	4.28	21.397

3.2. Preprocessing data

Pada tahap preprocessing ini dilakukan tiga tahapan utama untuk memastikan citra daun singkong memiliki kualitas yang optimal dan standar yang seragam sebelum memasuki proses pelatihan model, yaitu:

1. *Resize Data* (Penyesuaian Ukuran) Tahap awal dilakukan dengan mengubah seluruh resolusi citra menjadi ukuran standar 224x224 piksel menggunakan fungsi *RandomResizedCrop*. Penyeragaman dimensi ini sangat penting untuk menyesuaikan dengan syarat input shape dari arsitektur *EfficientNet-B0* serta berfungsi untuk mempercepat waktu komputasi selama proses iterasi berlangsung.



Gambar 3 Resize data

2. Normalisasi Data Setiap citra dikonversi ke dalam format tensor dan dilakukan normalisasi nilai piksel menggunakan nilai rata-rata (*mean*) dan standar deviasi dari dataset *ImageNet*.
3. Augmentasi Data

```

transforms.ColorJitter(
    brightness=0.3,
    contrast=0.3,
    saturation=0.3,
    hue=0.1
),

transforms.RandomAffine(
    degrees=0,
    translate=(0.1, 0.1),
    scale=(0.9, 1.1)
),

transforms.RandomPerspective(
    distortion_scale=0.2,
    p=0.3
).|
    
```

Gambar 4 augmentasi data

Pada gambar 4 diterapkan teknik augmentasi acak yang meliputi pembalikan posisi citra secara horizontal dan vertikal (*Random Flip*), rotasi sebesar 25 derajat, serta penyesuaian kecerahan dan kontras (*Color Jitter*). Langkah ini bertujuan agar model lebih tangguh (*robust*) dalam mengenali pola penyakit meskipun terdapat perbedaan sudut pengambilan gambar atau variasi cahaya di lapangan.

3.3. Pembagian data

Setelah tahap *preprocessing*, dataset sebanyak 21.397 citra dipisahkan menjadi dua bagian utama dengan rasio 80:20. Melalui pembagian ini, diperoleh 17.117 citra sebagai data latih untuk mempelajari pola visual penyakit, serta 4.280 citra sebagai data validasi untuk menguji kemampuan generalisasi model terhadap data baru. Pemisahan ini dilakukan secara otomatis menggunakan fungsi *random_split* dari *PyTorch* guna menjamin distribusi data yang acak dan objektif.

Selain pemisahan data, penelitian ini mengintegrasikan metode *WeightedRandomSampler* pada tahap data loader untuk menangani masalah ketidakseimbangan kelas (*class imbalance*). Teknik ini sangat krusial karena adanya dominasi jumlah sampel pada kelas *Cassava Mosaic disease (CMD)*. Dengan pengaturan sampel ini, setiap kategori penyakit mendapatkan bobot kepentingan yang seimbang selama iterasi pelatihan, sehingga mencegah model memiliki kecenderungan bias terhadap kelas mayoritas dan memastikan performa yang adil di seluruh kategori.

```

Cassava__mosaic_disease: 13152 images
Cassava__brown_streak_disease: 2107 images
Cassava__bacterial_blight: 1087 images
Cassava__green_mottle: 2382 images
Cassava__healthy: 2574 images
    
```

Gambar 5 Pembagian data

3.4 Pemodelan Arsitektur *EfficientNet* & *Transfer Learning*

Pembangunan model dalam penelitian ini mengimplementasikan arsitektur *EfficientNet-B0* sebagai ekstraktor fitur utama melalui teknik *Transfer Learning* dengan bobot *pre-trained* dari *ImageNet*. Pemilihan arsitektur ini didasarkan pada efisiensi mekanisme *Compound Scaling* yang mampu menyeimbangkan parameter model dengan akurasi secara optimal.

Dalam implementasinya, bagian *classifier head* dimodifikasi total dengan menyusun struktur baru yang terdiri dari lapisan *Dropout* 0,5 untuk mencegah *overfitting*, lapisan *Linear* (256 unit), fungsi aktivasi *ReLU*, serta *Batch Normalization* untuk

menstabilkan pelatihan. Struktur ini diakhiri dengan lapisan Linear final sebanyak 5 *neuron* sesuai jumlah kelas penyakit. Selain itu, diterapkan strategi *Partial Freezing* di mana lapisan awal dibekukan, sementara blok 6, 7, dan lapisan klasifikasi dibuka (*unfrozen*) untuk proses *fine-tuning* agar model dapat beradaptasi secara spesifik terhadap karakteristik visual citra penyakit daun singkong.


	Layer Name	Layer Type
0	backbone.features.0.0	Conv2d
1	backbone.features.0.1	BatchNorm2d
2	backbone.features.0.2	SiLU
3	backbone.features.1.0.block.0.0	Conv2d
4	backbone.features.1.0.block.0.1	BatchNorm2d
...
229	backbone.classifier.1	Linear
230	backbone.classifier.2	ReLU
231	backbone.classifier.3	BatchNorm1d
232	backbone.classifier.4	Dropout
233	backbone.classifier.5	Linear

Gambar 6 pemodelan dengan arsitektur *EfficientNet*

3.5 Pelatihan model

Proses pelatihan model dilakukan untuk mengoptimalkan bobot arsitektur *EfficientNet-B0* agar mampu meminimalkan kesalahan klasifikasi. Algoritma optimasi yang digunakan adalah *AdamW* dengan *learning rate* awal 0,001, yang dipilih karena kemampuannya dalam melakukan *weight decay* untuk regularisasi yang lebih baik. Perhitungan selisih prediksi menggunakan *Cross Entropy Loss* dengan teknik *Label Smoothing* sebesar 0,05 guna meningkatkan generalisasi dan mencegah model menjadi *overconfident*.

Skenario pelatihan ini juga menerapkan mekanisme *Cosine Annealing Learning Rate Scheduler* selama 10 *epoch* untuk menurunkan laju pembelajaran secara bertahap sehingga proses *fine-tuning* lebih stabil. Pelatihan dijalankan dengan *batch size* 32 menggunakan akselerator *GPU NVIDIA Tesla T4* untuk mempercepat komputasi. Selama proses berlangsung, metrik akurasi dan *loss* dipantau secara berkala guna memastikan peningkatan performa model yang konsisten tanpa gejala *overfitting*.




Gambar 7 grafik & loss

3.6 Evaluasi model

Tahap evaluasi dilakukan untuk mengukur kemampuan model dalam mengklasifikasikan citra penyakit daun singkong pada data validasi. Berdasarkan hasil pengujian selama 10 *epoch*, model *EfficientNet-B0* berhasil mencapai tingkat akurasi sebesar 76%. Performa ini dianalisis lebih mendalam menggunakan *Classification Report* yang menyajikan metrik presisi, recall, dan *F1-Score* untuk setiap kategori secara detail.

Hasil evaluasi menunjukkan bahwa model memiliki kemampuan deteksi tertinggi pada kelas *Cassava Mosaic disease (CMD)*. Hal ini didukung oleh jumlah sampel data *CMD* yang dominan, sehingga model dapat mengekstraksi fitur visualnya secara lebih mendalam. Sementara itu, pada kelas dengan sampel terbatas seperti *Cassava Bacterial blight (CBB)*, model tetap menunjukkan performa kompetitif berkat penerapan *Weighted Random Sampler* dan *Label Smoothing*. Secara keseluruhan, integrasi *EfficientNet-B0* dengan *Transfer Learning* terbukti efektif menghasilkan keseimbangan performa yang baik di seluruh metrik evaluasi.



Gambar 8 confusion matrix

4. KESIMPULAN

Penelitian ini berhasil menghasilkan model *Deep Learning* yang optimal untuk klasifikasi penyakit daun singkong dengan mengimplementasikan arsitektur *EfficientNet-B0* dan pendekatan *Transfer Learning*. Hasil eksperimen menunjukkan model mencapai tingkat akurasi sebesar 81% pada data validasi, membuktikan efektivitas arsitektur dalam mengenali fitur visual penyakit yang kompleks. Keberhasilan ini didukung secara signifikan oleh tahapan prapemrosesan komprehensif, termasuk augmentasi citra dan penggunaan *Weighted Random Sampler* untuk mengatasi kendala ketidakseimbangan data antar kelas. Selain itu, integrasi strategi pelatihan menggunakan pengoptimal *AdamW*, label *Smoothing*, dan *learning rate Scheduler* terbukti memberikan stabilitas pada proses *konvergensi* sekaligus mencegah risiko *overfitting*. Secara keseluruhan, penelitian ini menyimpulkan bahwa kombinasi arsitektur efisien dengan teknik pengolahan data yang tepat mampu menghasilkan sistem deteksi dini yang handal. Model ini memiliki potensi besar untuk membantu petani meningkatkan akurasi identifikasi penyakit di lapangan guna menjaga produktivitas hasil panen.

DAFTAR PUSTAKA

- [1] C. Chen *et al.*, "EfficientNet : A Low-bandwidth IoT Image Sensor Framework for Cassava Leaf Disease Classification," vol. 33, no. 11, pp. 4031–4044, 2021.
- [2] M. Liu, H. Liang, and M. Hou, "Research on cassava disease classification using the multi-scale fusion model based on EfficientNet and attention mechanism," no. December, pp. 1–11, 2022, doi: 10.3389/fpls.2022.1088531.
- [3] J. Anitha and N. Saranya, "CCC Publications Cassava Leaf Disease Identification and Detection Using Deep Learning Approach," 2022.
- [4] A. H. Siregar, A. Nazir, I. Afrianty, E. Budianita, and F. Inani, "Jurnal Computer Science and Information Technology (CoSciTech) simvastatin," vol. 4, no. 3, pp. 626–635, 2023.
- [5] K. Citra, P. Daun, T. Menggunakan, M. Convolutional, and N. Network, "Jurnal Computer Science and Information Technology (CoSciTech) Tomato Leaf Disease Image Classification Using Convolutional Neural Network (CNN) Method With," vol. 6, no. 3, pp. 405–413, 2025.
- [6] U. Sirisha, R. Nakka, J. Hymavathi, S. Lalitha, S. P. Praveen, and D. A. Karras, "Enhancing Cassava Leaf Disease Detection through Traditional Segmentation and Attention-driven Deep Learning Approaches," *Int. J. Adv. Life Sci. Res.*, vol. 8, no. 4, pp. 138–157, 2025, doi: 10.31632/ijalsr.2025.v08i04.011.
- [7] E. Anggiratih, S. Siswanti, S. K. Octaviani, and A. Sari, "Klasifikasi Penyakit Tanaman Padi Menggunakan Model Deep Learning Efficientnet B3 dengan Transfer Learning," *J. Ilm. SINUS*, vol. 19, no. 1, p. 75, 2021, doi: 10.30646/sinus.v19i1.526.
- [8] D. S. Joseph, P. M. Pawar, and K. Chakradeo, "Real-Time Plant Disease Dataset Development and Detection of Plant Disease Using Deep Learning," *IEEE Access*, vol. 12, no. February, pp. 16310–16333, 2024, doi: 10.1109/ACCESS.2024.3358333.
- [9] Y. Vijayalata, N. Billakanti, K. Veeravalli, R. N. A. Deepa, and L. Kota, "Early Detection of Casava Plant Leaf Diseases using EfficientNet-B0," 2022 *IEEE Delhi Sect. Conf. DELCON 2022*, pp. 1–5, 2022, doi: 10.1109/DELCON54057.2022.9753210.