



Komparasi Model ResNet50 dan EfficientNetV2M dengan Penerapan Transfer Learning dan Fine Tuning pada Klasifikasi Penyakit Bercak Daun Tanaman Pisang

Muhammad Gimmas Manggara*, Anna Dina Kalifia

Fakultas Sains & Teknologi, Program Studi Informatika, Universitas Teknologi Yogyakarta, Sleman, Indonesia

Email: ^{1,*}gimmasmanggara@gmail.com, ²ad.kalifia@gmail.com

Email Penulis Korespondensi: gimmasmanggara@gmail.com

Abstrak—Pisang merupakan komoditas penting untuk membantu perekonomian Indonesia tapi, penyakit bercak yang sering terjadi di negara yang berada di wilayah tropis dapat menimbulkan masalah bagi industri ini. Tujuan penelitian ini ialah membangun dan membandingkan dua model yaitu ResNet50 yang sering dijadikan pembandingan utama dengan EfficientNetV2M sebagai model yang lebih baru. Dataset diperoleh dua sumber yang berada di platform mendeley data, dataset hasil penggabungan terdiri dari 1938 data yang dilabeli dengan 5 kelas yaitu, *cordana*, *pestalotiopsis*, *black sigatoka*, *yellow sigatoka*, *healthy*. Proses pra-proses dilakukan dengan membagi data menjadi pelatihan, validasi, dan pengujian dengan rasio 70:20:10, kemudian pengubahan ukuran dan memberikan bobot pada tiap kelas. Dua model dilatih dengan parameter yang sama dan metrik evaluasi seperti *accuracy*, *precision*, *recall*, *f1-score*, dan *loss*. Hasil evaluasi pengujian menunjukkan hasil model EfficientNetV2M dengan nilai metrik *accuracy* sebesar 94,92%, *precision* sebesar 95,49%, *recall* sebesar 92,23%, *f1-score* sebesar 93,70% dan *loss* sebesar 17,96%. Sementara ResNet50 dengan hasil nilai *accuracy* 91,88%, *precision* sebesar 90,97%, *recall* sebesar 87,59%, *f1-score* sebesar 89,14%, dan *Loss* sebesar 20,87%. Berdasarkan hasil evaluasi tersebut EfficientNetV2M merupakan model dengan performa lebih unggul untuk klasifikasi penyakit bercak daun pisang. Penelitian ini diharapkan bisa menjadi referensi untuk menentukan model yang efektif serta pembangunan sistem klasifikasi penyakit bercak tanaman daun pisang.

Kata Kunci: Klasifikasi Citra; Deep Learning; Penyakit Corak Daun Pisang; ResNet50; EfficientNetV2M; Transfer Learning; Fine Tuning

Abstract—Bananas are an important commodity to support the Indonesian economy, but the frequent occurrence of banana spot disease in tropical countries can cause problems for this industry. The purpose of this study is to build and compare two models, namely ResNet50, which is often used as the main comparison, with EfficientNetV2M as a newer model. The dataset was obtained from two sources on the Mendeley data platform. The combined dataset consists of 1938 data labeled with 5 classes: *cordana*, *pestalotiopsis*, *black sigatoka*, *yellow sigatoka*, and *healthy*. The preprocessing process was carried out by dividing the data into training, validation, and testing with a ratio of 70:20:10, then resizing and assigning weights to each class. Two models were trained with the same parameters and evaluation metrics such as accuracy, precision, recall, f1-score, and loss. The test evaluation results show the results of the EfficientNetV2M model test with an accuracy metric value of 94.92%, precision of 95.49%, recall of 92.23%, f1-score of 93.70% and loss of 17.96%. While ResNet50 with an accuracy value of 91.88%, precision of 90.97%, recall of 87.59%, f1-score of 89.14%, and Loss of 20.87%. Based on these evaluation results, EfficientNetV2M is a model with superior performance for the classification of banana leaf spot disease. This research is expected to be a reference for determining an effective model and developing a classification system for banana leaf spot disease.

Keywords: Image Classification; Deep Learning; Banana Leaf Pattern Disease; ResNet50; EfficientNetV2M; Transfer Learning; Fine Tuning

1. PENDAHULUAN

Pisang merupakan tanaman penting yang menjadi sumber utama pendapatan dan pekerjaan di wilayah tropis dan subtropis di seluruh dunia [1]. Nilai ekonomi dari komoditas ini sangat signifikan, tidak hanya sebagai pangan pokok tetapi juga sebagai barang ekspor [2]. Menurut data FAO (Food and Agriculture Organization), Indonesia merupakan produsen pisang terbesar ketiga di dunia, berada di bawah China dan India [3]. Pencapaian ini menunjukkan peran strategis Indonesia dalam pasar pisang global. Sementara itu, data dari BPS menunjukkan bahwa pisang merupakan buah dengan produksi terbesar pada tahun 2024 [4]. Dominasi pisang dalam produksi buah nasional ini menegaskan pentingnya upaya perlindungan tanaman untuk menjaga kestabilan pasokan. Penyakit, terutama yang disebabkan oleh fungi, dapat menyebabkan dampak signifikan pada produksi dan hasil panen pisang [5]. Pada [5] dijelaskan bahwa penyakit pada daun pisang seperti *black sigatoka* dan *yellow sigatoka* menyebabkan *nekrosis* atau kematian jaringan dini pada daun. Kondisi ini mengakibatkan buah matang prematur atau pematangan tidak merata, yang berpotensi memicu infeksi pascapanen [5]. Selain kedua penyakit *sigatoka* tersebut, penyakit seperti *cordana* dan *pestalotiopsis* juga sering dijumpai [6]. Kurangnya pengetahuan mengenai patogen menyebabkan kesalahan penanganan penyakit dan keterlambatan, yang pada akhirnya dapat menyebabkan gagal panen [6]. Secara tradisional, ahli patologi mendiagnosis penyakit tanaman secara visual. Sayangnya, cara ini kurang efektif dan sangat mahal, terutama dikarenakan area perkebunan yang luas [7]. Oleh karena itu, berkembangnya konsep pertanian cerdas menggunakan kecerdasan buatan dan *IoT* (Internet of things) dapat menjadi solusi untuk permasalahan ini [8]. Beberapa metode *machine learning* canggih yang terkait dengan perkembangan teknologi kecerdasan buatan dalam beberapa tahun terakhir, seperti *deep learning* dan *transfer learning*, telah mulai diterapkan untuk pengenalan gambar penyakit di bidang agrikultur [9]. Di saat ini salah satu model *deep learning* yang umum digunakan yaitu CNN (Convolutional Neural Networks) dapat mempelajari fitur-fitur citra secara otomatis dan berjenjang. Namun, pengadopsian metode-metode ini masih menghadapi sejumlah tantangan penting. Pada tingkat awal,



CNN mempelajari fitur dasar seperti warna dan kecerahan. Proses ini kemudian berlanjut dengan memperoleh detail lokal yang lebih spesifik, seperti tepi, sudut, dan garis. Pada akhirnya, CNN dapat mengekstrak informasi dan struktur yang lebih kompleks, misalnya tekstur dan bentuk [9]. dalam penerapannya model *deep learning* sangat bergantung pada dataset yang besar dikarenakan banyaknya jenis menyebabkan sulitnya untuk mencapai kebutuhan *modeling*. *Transfer learning* digunakan untuk menyelesaikan permasalahan ini, terutama saat tidak cukupnya data pelatihan pada saat pelatihan [9]. Banyak studi yang menggunakan *parameter-based transfer learning* dimana domain sumber (dataset global) dan domain target dapat saling berbagi parameter model [9].

Penelitian Sebelumnya seperti [10] mengoptimalkan arsitektur VGG16 untuk klasifikasi penyakit daun jagung seperti *blight*, *common rust*, dan *gray leaf spot* dengan menggunakan *transfer learning* ditambahkan juga dua model tambahan yang menjadi komparasi yaitu model ringan MobileNetV2 dan VGG16 *baseline*. Hasil pengujian mendapati VGG16 dengan *transfer learning* mendapatkan tingkat presisi uji sebesar 96%, sedangkan pada dua model lainnya berada dibawah yaitu *baseline* sebesar 93% dan MobileNetV3 berada jauh di 85%.

Penelitian berikutnya oleh [6] menggunakan CNN untuk klasifikasi penyakit daun pisang seperti *cordana*, *sigatoka*, *pestalotiopsis*. Dataset dibagi menjadi 70:20:10 dengan *epoch* maksimum di 80. Hasil pengujian didapatkan tingkat akurasi train sebesar 0.92% dan untuk uji sebesar 0.82%. Dataset yang kecil menyebabkan hasil kurang memuaskan dikarenakan menggunakan model CNN, hal ini dapat dibantu dengan menggunakan arsitektur model *pretrain* dan menerapkan *transfer learning*.


Penelitian selanjutnya oleh [11] mengimplementasikan augmentasi dan *transfer learning* untuk klasifikasi penyakit daun tomat. menggunakan model seperti ResNet50, VGG16, dan DenseNet121 yang di *pretrained* menggunakan dataset *PlantVillage*. Kemudian dilakukan augmentasi data secara manual seperti *rotating*, *flipping* dan sintesis menggunakan GAN (*Generative Adversarial Network*) untuk generasi data. Hasil pengujian didapatkan DenseNet121 menghasilkan performa terbaik dengan akurasi sebesar 0.95%, presisi sebesar 0.94%, recall sebesar 0.95, dan *f1-score* sebesar 0.94%. Penelitian lainnya oleh [12] mengimplementasikan model ResNet50 untuk mengklasifikasikan penyakit daun kopi robusta dimana data dilabeli menjadi 5 yaitu sehat, berpenyakit *Red Spider Mite*, berpenyakit *Rust level 1*, *Rust level 2*, *Rust level 3*, *Rust level 4*. *Preprocess* membagi data menjadi 70% data train, 10% data validation, dan 20% data testing. Penelitian dilakukan pada dua kasus yaitu *binaryclass* dan *multiclass*, dimana *binaryclass* memiliki data sebanyak 1560 gambar daun sehat. Sedangkan, data *multiclass* sebanyak 4275 gambar daun untuk semua kategori. Dari penelitian didapati kasus *binaryclass* dengan akurasi sebesar 92,68% dan nilai *f1-score* sebesar 92,88%, sedangkan pada kasus *multiclass* performa paling baik hanya mendapat akurasi sebesar 88,98% dan nilai *f1-score* sebesar 88,44%. Dari Nilai kinerja yang dihasilkan untuk klasifikasi kasus *multiclass* tidak sebaik nilai kinerja yang dihasilkan oleh klasifikasi kasus *binaryclass*. Penelitian terakhir oleh [13] menggunakan yolov7 untuk melakukan segmentasi daun dan buah tanaman cabai. Hasil segmentasi menciptakan 3 class yaitu cabai busuk, normal, dan patek dengan jumlah secara berurutan 229, 463, 278. Kemudian CNN dengan metode *transfer learning* dan *fine tuning* dengan arsitektur EfficientNetV2M untuk melakukan klasifikasi penyakit pada data buah dan daun yang telah tersegmentasi. Hasil pengujian segmentasi oleh yolov7 mendapatkan Tingkat akurasi 0.97% pada mAP50 sedangkan testing model EfficientNetV2M yang telah dilakukan *transfer learning* dan *fine tuning* mendapatkan akurasi sebesar 0.91% untuk penyakit daun dan 0.889% untuk penyakit buah cabai. Penelitian Penelitian diatas menunjukkan *deep learning* dalam konteks ini model CNN efektif untuk melakukan klasifikasi pada penyakit tanaman. Lebih lanjut, Penggunaan *parameter-based transfer learning* membantu secara signifikan dalam meningkatkan akurasi akibat kekurangan data dan *overfitting*. Mengingat rendahnya tingkat kinerja yang dihasilkan pada studi klasifikasi penyakit pisang sebelumnya pada penelitian [6], dengan akurasi uji hanya sebesar 0,82%, yang disebabkan oleh keterbatasan ukuran dataset, terlihat jelas adanya kesenjangan penelitian (*research gap*) dalam mengoptimalkan klasifikasi penyakit bercak tanaman pisang. Oleh karena itu, diperlukan komparasi sistematis mengenai penggunaan *transfer learning* untuk berbagai model yang dilatih sebelumnya (*pretraining model*) dan dataset pada kasus penyakit bercak daun pisang.

Tujuan utama penelitian ini adalah mengidentifikasi arsitektur model *deep learning* terbaik yang dikombinasikan dengan *transfer learning* dan *fine-tuning* untuk mencapai kinerja klasifikasi yang lebih optimal pada penyakit bercak daun pisang. Dalam konteks ini, penelitian akan menggunakan model ResNet50 sebagai pembanding utama untuk model EfficientNetV2 yang lebih baru. ResNet50 dipilih sebagai tolok ukur atau *baseline* klasik yang teruji, yang kekuatannya terletak pada *residual block*-nya. Sebaliknya, EfficientNetV2 mewakili model modern yang berfokus pada efisiensi parameter dan *Scaling Compound* terpadu. Dengan membandingkan stabilitas arsitektur klasik ResNet50 melawan efisiensi dan optimisasi penskalaan model modern EfficientNetV2. Penelitian ini diharapkan dapat menjadi referensi acuan terkait model yang cocok untuk penyakit bercak daun pisang. Kontribusi utama yang diusulkan adalah penciptaan model klasifikasi penyakit daun pisang yang optimal dengan kinerja melampaui studi terdahulu yang terbatas pada dataset kecil dan penerapan *transfer learning* dan *fine tuning*.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Tahapan penelitian mencakup proses penelitian yang dilakukan yaitu, pengumpulan dataset, penggabungan dan pemilahan dataset, *preprocessing* dataset, implementasi dan optimisasi model, evaluasi hasil pengujian, penggunaan model pada sistem. Gambar 1 menunjukkan gambaran alur proses tahapan penelitian yang dilakukan.



Gambar 1. Tahapan penelitian

Tujuan dari tahapan penelitian adalah untuk menjelaskan garis besar alur dari penelitian yang dilakukan. Penelitian dimulai dari pengumpulan dataset yang memiliki penyakit bercak tanaman. Dikarenakan dataset pertama hanya memiliki 2 dari penyakit yang diharapkan diperlukan penggabungan dengan dataset ke-dua agar sesuai dengan tujuan dari penelitian. Kemudian berlanjut ke tahap *Preprocessing*, ditahap ini data *resize*, dibagi menjadi subset dan melakukan *encoding* pada label. Setelah itu perubahan format warna dan mengatasi *imbalance* data. Setelah proses *preprocessing* selesai dilanjutkan dengan implementasi model dengan menggunakan model ResNet50 dan EfficientNetV2M dan penerapan *transfer learning* dan *fine tuning* pada kedua model. Setelah melakukan implementasi dan pelatihan, dilakukan evaluasi hasil pengujian pada data *test* dengan 4 parameter yaitu *accuracy*, *precision*, *recall*, *f1-score*. Di akhir akan dilakukan percobaan klasifikasi menggunakan model terbaik yang didapatkan. Penjelasan lebih lanjut terkait tahapan penelitian bisa dilihat dibawah ini:

a. Pengumpulan Dataset

Pengumpulan dataset dilakukan dengan cara *browsing* kata kunci *leaf spot disease* pada platform yang menyediakan dataset dan mempublikasikan dataset. Data yang dicari yaitu data penyakit bercak pada tanaman pisang yang disebabkan oleh fungi seperti black sigatoka, yellow sigatoka, pestalotiopsis, cordana, serta daun sehat. Data ini kemudian akan diproses hingga bisa digunakan sebagai dasar untuk klasifikasi penyakit bercak tanaman pisang.

b. Preprocessing Dataset

Tahap *preprocessing* merupakan fondasi penting untuk mempersiapkan data citra agar optimal untuk pelatihan model. Proses pertama data *splitting* dimana data dibagi menjadi 3 subset yaitu data *train*, *validation*, dan *test*. Selanjutnya dilakukan serangkaian proses yang dinamakan data *preparation*, seperti pengubahan ukuran citra atau *resizing*, kemudian mengubah data menjadi *array* untuk meningkatkan efisiensi komputasi saat pelatihan model [14], dan menentukan *batch*. Selain itu melakukan pembobotan untuk tiap kelas, terutama pada kelas minoritas diberikan bobot yang lebih tinggi. Hal ini dilakukan agar kelas minoritas mendapatkan perhatian lebih pada saat proses pelatihan [15].

c. Implementasi model

Implementasi model dilakukan dengan menerapkan *transfer learning* dan *fine tuning*. Penggunaan *transfer learning* dapat membantu permasalahan data target yang kecil [16]. *Transfer learning* memanfaatkan model yang sudah dilatih sebagai titik awal untuk mempelajari tugas baru [17]. Dalam pendekatan ini, model yang sudah terlatih pada dataset besar, seperti *ImageNet*, dapat diadaptasi menggunakan dua cara. Sebagian lapisan seperti lapisan-lapisan awal dari model *pre-trained* yang telah mempelajari representasi dan pola umum dapat dipertahankan atau *frozen* [17]. pada cara ini, model *pre-trained* bertindak sebagai ekstraktor fitur [17]. Lapisan-lapisan akhir dari model diganti dengan lapisan baru yang disesuaikan untuk tugas klasifikasi spesifik pada dataset target, seperti data penyakit bercak daun pisang. Selanjutnya, menerapkan *fine tuning*, *fine tuning* sendiri merupakan cara umum untuk transfer pengetahuan dalam *deep learning* [17]. Dalam proses ini, lapisan-lapisan yang sebelumnya dibekukan dapat diaktifkan kembali atau *unfrozen* dan dilatih bersama lapisan baru. Penyesuaian bobot pada lapisan *unfrozen* ini dilakukan selama *backpropagation*, yang berfungsi untuk menyempurnakan fitur-fitur yang telah dipelajari agar lebih selaras dengan tujuan spesifik dari pengklasifikasi tugas *downstream classifier* [17].

d. Evaluasi Hasil Pengujian

Evaluasi Pengujian dilakukan dengan menggunakan metrik evaluasi. metrik evaluasi adalah alat yang digunakan untuk mengukur kinerja dan efektivitas model, terutama dalam tugas klasifikasi. Metrik ini menyediakan cara kuantitatif untuk memahami seberapa baik model membuat prediksi dan, yang lebih penting, jenis kesalahan apa yang dilakukannya. Metrik seperti *accuration* (Jumlah prediksi akurat (*True Positive* (TP) ditambah *True Negative* (TN)) dibagi dengan jumlah total semua *instance* dalam himpunan data (P ditambah N)), *Precision* (Jumlah prediksi positif yang benar (TP) dibagi dengan jumlah total prediksi positif (TP ditambah *False Positive* (FP)), *Recall* (juga dikenal sebagai *Sensitivity* atau *True Positive Rate* (TP Rate)), dan *F1-Score* (ukuran akurasi uji yang didasarkan pada *Precision* dan *Recall*) digunakan [18]. Rumus metrik umum yang dipakai sebagai berikut.

$$ACC = \frac{TP+TN}{P+N} = \frac{TP+TN}{TP+TN+FN+FP} \quad (1)$$

$$PREC = \frac{TP}{TP+FP} \quad (2)$$

$$SN = \frac{TP}{TP+FN} = \frac{TP}{P} \quad (3)$$

$$F - Score = \frac{2 \times precision \times recall}{precision + recall} \quad (4)$$

Dimana ACC = *accuracy*, PREC = *precision*, SN = *recall*, F-Score = *f1-score*, TP (True Positive) = Prediksi positif yang benar, TN (True Negative) = Prediksi negatif yang benar, FP (False Positive) = Prediksi positif yang salah (Error Tipe 1), FN (False Negative) = Prediksi negatif yang salah (Error Tipe 2) [18].

Selain metrik tunggal, ada *Confusion Matrix* yang menawarkan teknik terperinci dan mendalam untuk mengevaluasi kinerja *classifier* (model klasifikasi) [19]. *Confusion matrix* ini berfungsi sebagai alat vital untuk menilai model klasifikasi *machine learning* [19]. Matriks ini merupakan matriks persegi dengan ukuran N x N di mana N mewakili jumlah kelas *output*. Setiap baris dalam matriks merepresentasikan jumlah instansi dari kelas yang diprediksi, dan setiap kolom menunjukkan jumlah instansi dari kelas aktual. Dengan demikian, *Confusion Matrix* memberikan perincian kelas-per-kelas mengenai jumlah prediksi yang akurat dan prediksi yang tidak akurat yang dibuat oleh *classifier* untuk tugas klasifikasi, baik biner maupun *multiclass* [19].

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan data

Dataset yang diperlukan dalam penelitian ini yaitu, dataset penyakit bercak daun yang disebabkan oleh fungi seperti *black sigatoka*, *yellow sigatoka*, *pestalotiopsis* yang dapat menyebabkan kerugian panen jika tidak segera ditangani. Adapun sampel data citra penyakit bercak daun seperti ditunjukkan pada Gambar 2.



Gambar 2. Citra daun pisang per-kelas

Gambar 2 menyajikan lima contoh visual dari kondisi daun pisang yang berbeda, mencakup empat jenis penyakit dan satu kondisi sehat, yang merupakan bagian dari dataset yang digunakan untuk pelatihan model klasifikasi. Kondisi yang ditampilkan yaitu, *black sigatoka* cirinya menunjukkan bercak-bercak gelap, seringkali dengan halo kuning, *cordana* ditandai dengan area nekrotik berwarna coklat besar dengan batas yang jelas, *healthy* dengan daun berwarna hijau seragam, tanpa gejala penyakit, *pestalotiopsis* menampilkan bercak-bercak coklat atau lesi nekrotik, khususnya di tepi daun, dan *yellow sigatoka* menunjukkan pola menguning atau *chlorosis*, terutama sejajar dengan urat daun. Gambar 2 menyoroti variasi gejala yang harus dipelajari dan dibedakan oleh model deep learning untuk klasifikasi yang akurat. Dataset yang digunakan merupakan dataset teraugmentasi, terdiri dari 1.938 data yang terdiri dari 4 kelas yang diambil dari hasil gabungan dua sumber yaitu [20] dan [21]. Dataset [20] memiliki data untuk kelas daun *healthy*, *cordana* dan *pestalotiopsis*, dan *sigatoka*. Sedangkan, data kedua memiliki data untuk kelas *black sigatoka* dan *yellow sigatoka*. data Distribusi dataset ditunjukkan pada tabel 1. Alasan tidak dipakainya kelas *sigatoka* dikarenakan *yellow sigatoka* dan *black sigatoka* memiliki penyebab yang berbeda. Pada *black Sigatoka* disebabkan oleh jamur *Pseudocercospora fijiensis* sedangkan pada *yellow Sigatoka* disebabkan oleh *P. Musae* [22].

Tabel 1. Distribusi data kelas

Kelas	Jumlah
<i>Healthy</i>	400
<i>Cordana</i>	400
<i>Pestalotiopsis</i>	400
<i>Yellow Sigatoka</i>	264
<i>Black Sigatoka</i>	474

Tabel 1 menunjukkan adanya imbalance pada dataset dikarenakan distribusi yang tidak merata. Masalah ini akan dibahas di saat pelatihan dan *preprocessing*, tentang bagaimana caranya menangani masalah data yang tidak terdistribusi dengan baik. Dataset pertama sendiri memiliki resolusi sebesar 224 x 224 dan dataset kedua memiliki resolusi sebesar 256 x 256. Pada kedua dataset telah dilakukan proses augmentasi seperti *Gaussian blur*, *horizontal flip*, *cropping*, *linear contrast adjustment*, *shear*, *translation*, dan *rotational shear*.

3.2 Preprocessing data

Langkah pertama dari preprocessing data, yaitu data *preparation* melibatkan penyeragaman dimensi, di mana semua gambar disesuaikan ukurannya menjadi 256 x 256 piksel atau *resizing*. Proses ini dilakukan untuk memastikan konsistensi

data yang diperlukan oleh model jaringan saraf konvolusi, serta untuk menurunkan beban komputasi seperti yang telah dibahas pada tahapan penelitian. Selanjutnya, dataset dibagi menjadi tiga subset atau data *splitting*, yaitu: *train*, *validation*, dan *test*, yang secara berurutan sebesar 70%, 20%, dan 10%. Subset *train* data yang digunakan untuk melatih model. Subset *validation* digunakan untuk melakukan validasi bersamaan selama proses pelatihan. Subset *test* digunakan untuk pengujian model terhadap data yang belum pernah dilihat oleh model sebelumnya. Tabel 2 menunjukkan distribusi subset *training*, *validation*, dan *test*.

Tabel 2. Distribusi subset data

Subset	Jumlah
<i>Train</i>	1355
<i>Validation</i>	386
<i>Test</i>	197

Pada prosesnya pembagian subset menggunakan beberapa parameter seperti *batch size* sebesar 32. Setelah pemuatan subset data, label kelas dikonversi menjadi format *one-hot encoded* atau kategori sehingga menjadi 5 label unik. Yang terakhir, karena data menunjukkan ketidakseimbangan kelas yang signifikan (terutama antara *black sigatoka* dan *healthy*), diterapkan penyeimbangan dengan bobot tiap kelas atau *balanced class weights* nantinya pada fase pelatihan. Penyesuaian ini memastikan bahwa model kelas-kelas minoritas lebih diperhatikan, mencegah bias, dan memaksimalkan kinerja klasifikasi di seluruh kelas.

3.3 Implementasi Model

Implementasi model diperlakukan sama pada kedua model yaitu dirancang sebagai proses *transfer learning* dua fase. Tahap persiapan awal menentukan metrik evaluasi seperti *precision*, *recall*, dan *f1-score*. Selanjutnya, karena data menunjukkan adanya ketidakseimbangan kelas, diterapkan *balance class weight* sepanjang pelatihan. Fase pertama berfokus pada pelatihan lapisan klasifikasi atau *head* baru yang ditambahkan di atas *backbone pretrain* model, di mana bobot backbone dipertahankan atau dibekukan dan hanya head yang dilatih menggunakan *optimizer* Adam dengan *learning rate* awal 1×10^{-4} . Setelah head dikonfigurasi, implementasi beralih ke fase kedua, yaitu *fine tuning*, di mana 25 lapisan terakhir dari *backbone pretrain* model dicairkan atau *unfrozen*. Model kemudian dikonfigurasi ulang dengan *learning rate* yang jauh lebih kecil 1×10^{-6} untuk penyesuaian bobot. Proses pelatihan ini dipantau menggunakan *callback EarlyStopping* yang berfokus pada peningkatan *validation F1-Score* untuk menghentikan pelatihan pada titik kinerja optimal dan mencegah *overfitting*. Pada Gambar 3 ditunjukkan arsitektur yang diimplementasikan.

Model: "sequential"			Model: "sequential"		
Layer (type)	Output Shape	Param #	Layer (type)	Output Shape	Param #
resnet50 (Functional)	(None, 8, 8, 2048)	23,587,712	efficientnetv2-m (Functional)	(None, 15, 15, 1280)	53,150,388
flatten (Flatten)	(None, 131072)	0	flatten (Flatten)	(None, 288000)	0
dense (Dense)	(None, 256)	33,554,688	dense (Dense)	(None, 256)	73,728,256
dense_1 (Dense)	(None, 256)	65,792	dense_1 (Dense)	(None, 256)	65,792
dropout (Dropout)	(None, 256)	0	dropout (Dropout)	(None, 256)	0
dense_2 (Dense)	(None, 5)	1,285	dense_2 (Dense)	(None, 5)	1,285
Total params: 144,433,297 (550.97 MB)			Total params: 288,531,909 (1.07 GB)		
Trainable params: 43,611,989 (166.37 MB)			Trainable params: 88,793,893 (388.20 MB)		
Non-trainable params: 13,597,348 (51.87 MB)			Non-trainable params: 46,152,638 (176.06 MB)		
Optimizer params: 87,223,820 (332.73 MB)			Optimizer params: 161,586,188 (616.40 MB)		

Gambar 3. Arsitektur implementasi ResNet50 dan EfficientNetV2M

Pada Gambar 3 bisa dilihat layer pertama (*head*) *backbone* dari ResNet50 dan EfficientNetV2M yang dilatih dengan dataset skala besar yaitu *imagenet*. Setelahnya lapisan untuk ekstraksi kelima kelas dataset lokal sebelumnya. Lapisan seperti *flatten* yang mengubah *feature* menjadi *vector*. Dua lapisan *dense* dengan unit sebesar 256, *dropout* dengan rate sebesar 0.7 untuk regulasi mencegah terjadinya *overfitting*. Dan lapisan output dengan 5 unit sesuai dengan 5 kelas penyakit bercak. Dari gambar 3 juga ditunjukkan jumlah parameter yang digunakan pada kedua model. Model EfficientNetV2M menunjukkan jumlah dua kali lipat lebih banyak daripada ResNet50. Kemudian data dilatih dengan *patience* sebesar 5 untuk mencegah *overfitting* dan efisiensi waktu pelatihan. Tabel 3 menunjukkan *hyperparameter* pelatihan yang sudah disebutkan dalam penjelasan sebelumnya.

Tabel 3. *Hyperparameter* pelatihan

<i>Hyperparameter</i>	Fase 1 (Head Training)	Fase 2 (Fine-Tuning)
<i>Optimizer</i>	Adam	Adam
<i>Loss Function</i>	Categorical Cross-Entropy	Categorical Cross-Entropy
<i>Initial Learning Rate (LR)</i>	1×10^{-4}	1×10^{-6}



Hyperparameter	Fase 1 (Head Training)	Fase 2 (Fine-Tuning)
Layers Unfrozen	0 (Hanya Head)	25 lapisan terakhir
Epochs (Max)	30	100
Early Stopping Monitor	-	val_f1_m
Early Stopping Patience	-	5

3.4 Evaluasi Hasil Pengujian

Implementasi dilakukan dengan menggunakan *python* dengan *framework tensorflow* dan *keras* dan dijalankan pada *google collab* dengan menggunakan bantuan GPU T4 untuk mempercepat proses pelatihan. Pelatihan model *pretrain* untuk klasifikasi penyakit daun pisang menggunakan strategi *transfer learning* dengan arsitektur *backbone* ResNet50 dan EfficientNetV2M menghasilkan model yang sangat efektif dalam mengidentifikasi lima kondisi daun spesifik: *black sigatoka*, *cordana*, *healthy*, *pestalotiopsis*, dan *yellow sigatoka*. Kinerja model dinilai berdasarkan beberapa metrik seperti *accuracy*, *Precision*, *Recall*, dan *F1-Score*. Dikarenakan adanya *imbalance* dataset dikarenakan kelas tidak terdistribusi dengan baik, dilakukan penghitungan tiap bobot kelas. Implementasi dilakukan dengan fungsi dari *scikit-learn* yang secara otomatis menyesuaikan bobot secara berbanding terbalik pada frekuensi kelas. Detail rumus pada fungsi ini seperti berikut ini [23].


$$W_i = \frac{n_{samples}}{n_{classes} \times n_{samples,i}} \quad (5)$$

Di mana W_i adalah bobot kelas i , $n_{samples}$ merupakan total seluruh sampel dalam dataset, $n_{classes}$ adalah jumlah kategori atau kelas unik, dan $n_{samples,i}$ menunjukkan jumlah sampel pada kelas i [23]. Bobot yang diberikan pada tiap kelas dapat dilihat pada Tabel 4.


Tabel 4. Bobot Kelas

Kelas	Bobot
Healthy	0,968
Cordana	0,968
Pestalotiopsis	0,968
Yellow Sigatoka	0,819
Black Sigatoka	1,473

Selanjutnya pada proses pelatihan dipantau menggunakan data *validation* untuk menentukan titik kinerja optimal, yang digunakan pada *early stoping monitor* sesuai dengan yang ditunjukkan pada tabel 3. Model juga dilatih dengan *balanced class weights* yang telah ditetapkan sebelumnya untuk memastikan sampel dari kelas minoritas seperti *healthy leaf* sesuai yang ditunjukkan pada tabel 1 memiliki dampak yang proporsional terhadap *loss function* dibandingkan dengan kelas mayoritas yaitu *black sigatoka*. Penggunaan *callback EarlyStopping* berfokus pada peningkatan *validation F1-Score* seperti yang dijelaskan sebelumnya dapat menghentikan proses *fine tuning* secara tepat dan menyimpan bobot model terbaik. Dari hasil pelatihan model EfficientNetV2M berhenti pada *epoch* 81. Sedangkan, pada model ResNet50 model berhenti pada *epoch* yang lebih rendah yaitu 59. Hasil kurva *loss* kedua model dapat dilihat pada gambar 4 dan 5 menunjukkan hasil yang lumayan mirip metrik validasi mengikuti metrik pelatihan, namun pada kurva ResNet50 menunjukkan model kurang baik untuk menangani data training di *epoch* awal. Namun, seiring berjalannya training model mulai bisa menangani baik data training maupun validasi dan bisa disimpulkan bahwa model berjalan dengan cukup baik khususnya EfficientNetv2m yang dari awal kedua data saling mendekati. Hal ini membuktikan kalau model tidak mengalami *overfitting* dikarenakan, [24] menyebutkan kondisi *non-overfitting* jika kedua *loss* (*Training* dan *Validation*) menunjukkan tren menurun bersamaan dan tetap berdekatan atau stabil pada nilai rendah.



Gambar 4. Kurva loss EfficientNetV2M



Gambar 5. Kurva loss ResNet50

Setelah melihat kurva *loss*, beralih pada evaluasi data *test* untuk menilai kemampuan sejati kedua model dalam mengklasifikasikan citra daun pisang yang belum pernah ditemui. Tabel 5 menyajikan perbandingan metrik evaluasi dari pengujian kedua model, yang secara tegas menempatkan EfficientNetV2M sebagai arsitektur yang lebih unggul untuk tugas ini. Secara keseluruhan, EfficientNetV2M menunjukkan dominasi lebih. Model ini unggul pada metrik utama seperti *test accuracy* sebesar 94.92% melampaui ResNet50 sebesar 3.04% dan *test precision* sebesar 95.49% melampaui ResNet50 sebesar 4.52%. Keunggulan ini diperkuat oleh nilai *test loss* yang lebih rendah pada EfficientNetV2M sebesar 0.0291, yang mengindikasikan prediksi model ini memiliki tingkat keakuratan yang lebih tinggi. Selain itu, *test F1-Score* EfficientNetV2M juga unggul sebesar 4,56% yaitu 93,70% berbanding 89,14% milik ResNet50. Pada metrik *test recall* EfficientNetV2M unggul sebesar 4,64% yaitu 92,23% berbanding 87,59% milik ResNet50, dominasi EfficientNetV2M pada semua metrics iniz secara kolektif membuktikan bahwa EfficientNetV2M lebih unggul dan seimbang. Hasil ini secara definitif menyimpulkan bahwa EfficientNetV2M tidak hanya memiliki kinerja yang lebih tinggi, tetapi juga kemampuan yang lebih baik untuk menggeneralisasi dan menghadapi data yang belum pernah ditemui. Kemampuan generalisasi ini menjadikannya pilihan yang lebih andal untuk implementasi praktis dalam sistem deteksi penyakit daun pisang.

Tabel 4. Metrik Evaluasi hasil test

Model	<i>accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	<i>Loss</i>
EfficientNetV2M	0,9492	0,9549	0,9223	0,9370	0.1796
ResNet50	0,9188	0,9097	0,8759	0,8914	0,2087

Berikutnya melihat evaluasi kinerja model pada data uji melalui *Classification Report* untuk memahami persentase keberhasilan model pada setiap kelas dan untuk mengukur seberapa baik model mengatasi ketidakseimbangan data. Hasil perbandingan antara EfficientNetV2M dan ResNet50 menunjukkan perbedaan signifikan dalam kemampuan generalisasi kedua model. Model EfficientNetV2M ditunjukkan pada Gambar 6 secara konsisten menunjukkan kinerja yang baik dan lebih stabil di seluruh metrik. Model ini berhasil mencapai *accuracy* keseluruhan sebesar 95%. Pada *macro average*, EfficientNetV2M mencatatkan nilai yang seragam dan tinggi, yaitu sebesar 95%. Konsistensi yang ditunjukkan oleh nilai *macro average* yang seragam ini adalah bukti langsung bahwa EfficientNetV2M telah berhasil menggeneralisasi secara efektif, mempertahankan kinerja tinggi pada semua lima kelas penyakit, termasuk kelas minoritas. Sebaliknya, ResNet50 ditunjukkan pada Gambar 7 menunjukkan persentase metrik evaluasi yang sedikit lebih rendah, mengindikasikan adanya kendala generalisasi yang lebih besar. Meskipun *macro average precision* dan *macro average F1-Score* ResNet50 tetap kuat di 92%, metrik yang mengukur daya tangkap model menunjukkan penurunan, *macro average recall* sebesar 91%. Penurunan 1% pada *macro average recall* ini menunjukkan bahwa ResNet50 memiliki probabilitas lebih tinggi untuk gagal mendeteksi kasus penyakit negatif (*true negatives*), terutama pada kelas-kelas yang memiliki sampel lebih sedikit. Berdasarkan *classification report*, EfficientNetV2M jelas lebih konsisten dan andal dalam mengklasifikasikan kelima kelas. Konsistensi yang tinggi pada metrik *macro average* sebesar 95% dan perbedaan performa dari ResNet50 menegaskan bahwa arsitektur EfficientNetV2M, dengan *fine tuning* yang dikontrol merupakan pilihan optimal karena menghasilkan model dengan kualitas prediksi dan kemampuan generalisasi yang superior.

Classification Report:				
	precision	recall	f1-score	support
BLACK SIGATOKA	0.96	0.94	0.95	49
CORDANA	1.00	1.00	1.00	40
HEALTHY LEAF	0.91	0.97	0.94	40
PESTALOTIOPSIS	0.97	0.90	0.94	40
YELLOW SIGATOKA	0.90	0.93	0.91	28
accuracy			0.95	197
macro avg	0.95	0.95	0.95	197
weighted avg	0.95	0.95	0.95	197


Gambar 6. Classification report EfficientNetV2M




Classification Report:				
	precision	recall	f1-score	support
BLACK SIGATOKA	0.92	0.98	0.95	49
CORDANA	1.00	0.93	0.96	40
HEALTHY LEAF	0.87	1.00	0.93	40
PESTALOTIOPSIS	0.88	0.88	0.88	40
YELLOW SIGATOKA	0.95	0.75	0.84	28
accuracy			0.92	197
macro avg	0.92	0.91	0.91	197
weighted avg	0.92	0.92	0.92	197

Gambar 7. Classification report ResNet50

Selanjutnya melihat *confusion matrix* yang dihasilkan oleh kedua model. Matrik ini berguna untuk melihat kemampuan klasifikasi kedua model pada tiap kelas. Gambar 8 dan 9 menunjukkan *confusion matrix* dari model EfficientNetV2M dan ResNet50. Secara keseluruhan, EfficientNetV2M menunjukkan kinerja yang lebih baik dengan total 187 klasifikasi yang benar dibandingkan dengan 181 klasifikasi yang benar pada ResNet50. Namun, kekuatan kedua model ini berbeda berdasarkan kelas. EfficientNetV2M lebih unggul dalam mengidentifikasi penyakit *black sigatoka*, 48 kasus teridentifikasi dengan benar berbanding 46 pada ResNet50. Kelas *cordana* pada EfficientNetV2M mengidentifikasi benar sebesar 40 berbanding 37 pada ResNet50 yang lebih sedikit. EfficientNetV2M juga lebih akurat dalam mengidentifikasi *yellow sigatoka*, sebesar 26 kasus teridentifikasi dengan benar berbanding 21 pada ResNet50. Sementara pada kelas *healthy*, ResNet50 sedikit lebih unggul sebesar 40 berbanding 39 pada EfficientNetV2M. Dari analisis *confusion matrix* EfficientNetV2M unggul pada identifikasi kelas *cordana* dimana model dapat mengidentifikasi kelas tanpa kesalahan. Sedangkan pada ResNet50 unggul pada identifikasi kelas *healthy* seperti EfficientNetV2M dapat mengidentifikasi tanpa kesalahan. Hasil Analisis- analisis diatas menunjukkan EfficientNetV2M unggul dari jumlah benar dari tiap kelas yang diidentifikasi walaupun, kelas yang diidentifikasi tanpa kesalahan sama dengan ResNet50.



Gambar 8. Confusion matrix EfficientNetV2M




Gambar 9. Confusion matrix ResNet50

Dari metrik-metrik yang telah dijelaskan model EfficientNetV2M bisa disimpulkan jauh mengungguli ResNet50, baik dari metrik seperti *accuracy*, *precision*, *recall*, *f1-score* maupun pada *confusion matrix*.

3.5 Klasifikasi penyakit

Klasifikasi dilakukan dengan menggunakan kedua model pada sistem. Memperlihatkan kemampuan kedua model untuk melakukan klasifikasi 5 kelas penyakit corak tanaman pisang. Gambar 11 menunjukkan hasil dari klasifikasi.



Gambar 10. Klasifikasi daun pisang

Pada Gambar 11 menunjukkan kinerja yang baik citra daun berhasil diklasifikasi secara tepat.

4. KESIMPULAN

Dari hasil pengujian dan evaluasi yang telah dilakukan, dapat disimpulkan bahwa arsitektur model EfficientNetV2M menunjukkan performa lebih baik dibandingkan dengan ResNet50 dalam tugas klasifikasi penyakit corak daun pada tanaman pisang. Hasil pengujian menunjukkan bahwa EfficientNetV2M mencapai angka tertinggi pada kelima metrik evaluasi utama yaitu, akurasi sebesar 94,92%, presisi sebesar 95,49%, *recall* sebesar 92,23% *f1-Score* sebesar 93,70, dan nilai *Loss* yang lebih rendah sebesar 17,96%. Capaian ini secara konsisten melampaui metrik evaluasi ResNet50, yang mencatatkan akurasi 91,88%, presisi sebesar 90,97%, *recall* sebesar 87,59%, *f1-score* sebesar 89,14%, dan *loss* sebesar 20,87%. Keunggulan EfficientNetV2M semakin diperkuat oleh kinerja stabil pada *classification report* dengan perhitungan *macro average yang lebih baik*, dominasi dengan *accuration 95%*, semua *macro average 95%*. Sementara itu, ResNet50 mencatatkan *accuration 92%*, *macro average precision 92%*, *macro average recall 91%*, dan *macro average F1-score 91%*. Meskipun *confusion Matrix* menunjukkan ResNet50 unggul dalam klasifikasi tunggal kelas *Black Sigatoka* dan kelas *Healthy* diindikasikan dengan 48 dan 40 benar, EfficientNetV2M balas dengan keunggulan pada 3 kelas lainnya. Selain itu, EfficientNetV2M juga unggul pada klasifikasi benar, yaitu 187 dibandingkan 181 milik ResNet50. Secara keseluruhan, metrik-metrik ini secara tegas menegaskan bahwa EfficientNetV2M memiliki kombinasi terbaik antara ketepatan dan kelengkapan prediksi, menjadikannya arsitektur yang paling optimal dan direkomendasikan untuk implementasi sistem deteksi penyakit daun pisang secara dini. Namun demikian, performa tinggi ini didapatkan dari dataset terbatas yang memiliki ukuran dan kelas yang terbatas. Oleh karena itu, penelitian selanjutnya perlu memperluas cakupan dataset dalam hal ini varietas penyakit, serta tingkat keparahan penyakit yang lebih beragam guna meningkatkan kemampuan model pada permasalahan yang lebih kompleks.

REFERENCES

- [1] M. K. Haq, K. Tanvir, Md. S. Kabir, N. S. B. Alam, S. K. Dey, and V. Raju, "Enhancing Banana Leaf Spot Disease Classification using Dense Mobilenet V2," in *2024 International Conference on Advances in Computing, Communication and Applied Informatics (ACCAI)*, 2024, pp. 1–6. doi: 10.1109/ACCAI61061.2024.10602228.



- [2] I. Sulistyowarni, S. Sundari, and D. S. Halim, "THE POTENTIAL OF BANANA TRADING COMMODITY TO FULFILL MARKET DEMAND AND SUPPORT FOOD SECURITY IN DEFENSE ECONOMIC PERSPECTIVE (STUDY IN BOGOR REGENCY)," *Jurnal Pertahanan dan Bela Negara*, vol. 10, no. 3, pp. 307–332, 2020, doi: <https://doi.org/10.33172/jpbh.v10i3.1114>.
- [3] Food and Agriculture Organization of the United Nations (FAO), "Production/Yield quantities of Bananas in Indonesia." Accessed: Mar. 06, 2025. [Online]. Available: <https://www.fao.org/faostat/en/#data/QCL/visualize>
- [4] Badan Pusat Statistik, "Produksi Tanaman Buah-buahan dan Sayuran Tahunan Menurut Provinsi dan Jenis Tanaman, 2024." Accessed: Jan. 10, 2025. [Online]. Available: <https://www.bps.go.id/id/statistics-table/3/U0dKc1owczVSalJ5VFdOMWVETnIVRVJ6YIRJMFp6MDkjMw==/produksi-tanaman-buah-buahan-dan-sayuran-tahunan-menurut-provinsi-dan-jenis-tanaman--2024.html?year=2024>
- [5] J. G. Esguera, M. A. Balendres, and D. P. Paguntalan, "Overview of the Sigatoka leaf spot complex in banana and its current management," *Tropical Plants*, vol. 3, no. 1, pp. 0–0, 2024, doi: 10.48130/tp-0024-0001.
- [6] M. D. Pratama, R. Gustriansyah, and E. Purnamasari, "Klasifikasi Penyakit Daun Pisang menggunakan Convolutional Neural Network (CNN)," *Jurnal Teknologi Terpadu*, vol. 10, no. 1, pp. 1–6, Jul. 2024, doi: 10.54914/jtt.v10i1.1167.
- [7] Md. A. B. Bhuiyan, H. M. Abdullah, S. E. Arman, S. Saminur Rahman, and K. Al Mahmud, "BananaSqueezeNet: A very fast, lightweight convolutional neural network for the diagnosis of three prominent banana leaf diseases," *Smart Agricultural Technology*, vol. 4, p. 100214, 2023, doi: <https://doi.org/10.1016/j.atech.2023.100214>.
- [8] C. Singh, S. Chadha, S. Bathrinath, I. Dixit, P. Suganthi, and T. Sathish, "IoT-Based Smart Cities: Challenges and Future Perspectives," in *Proceedings of 9th International Conference on Science, Technology, Engineering and Mathematics: The Role of Emerging Technologies in Digital Transformation, ICONSTEM 2024*, Institute of Electrical and Electronics Engineers Inc., 2024, doi: 10.1109/ICONSTEM60960.2024.10568658.
- [9] Y. Yuan, L. Chen, H. Wu, and L. Li, "Advanced agricultural disease image recognition technologies: A review," *Information Processing in Agriculture*, vol. 9, no. 1, pp. 48–59, 2022, doi: <https://doi.org/10.1016/j.inpa.2021.01.003>.
- [10] A. I. R. Ht. Barat, W. S. Astuti, A. Wanto, and S. Solikhun, "Optimisasi VGG16 dengan Transfer Learning dalam Mendeteksi Penyakit Pada Daun Jagung," *Bulletin of Computer Science Research*, vol. 5, no. 5, pp. 1049–1058, Aug. 2025, doi: 10.47065/bulletincsr.v5i5.631.
- [11] W. G. Pamungkas, M. I. P. Wardhana, Z. Sari, and Y. Azhar, "Leaf Image Identification: CNN with EfficientNet-B0 and ResNet-50 Used to Classified Corn Disease," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 2, pp. 326–333, Mar. 2023, doi: 10.29207/resti.v7i2.4736.
- [12] I. Awaludin *et al.*, "Analisis Kinerja ResNet-50 dalam Klasifikasi Penyakit pada Daun Kopi Robusta," *JURNAL INFORMATIKA*, vol. 9, no. 2, 2022, [Online]. Available: <http://ejournal.bsi.ac.id/ejurnal/index.php/ji>
- [13] M. Anwar, Y. Kristian, and E. Setyati, "CLASSIFICATION OF CHILI PLANT DISEASES EQUIPPED WITH LEAF AND FRUIT IMAGE SEGMENTATION USING YOLO V7," *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 6, no. 1, 2023.
- [14] A. Tatar, M. Haghighi, and A. Zeinijahromi, "Experiments on image data augmentation techniques for geological rock type classification with convolutional neural networks," *Journal of Rock Mechanics and Geotechnical Engineering*, vol. 17, no. 1, pp. 106–125, 2025, doi: <https://doi.org/10.1016/j.jrmge.2024.02.015>.
- [15] K. De Angeli *et al.*, "Class imbalance in out-of-distribution datasets: Improving the robustness of the TextCNN for the classification of rare cancer types," *J Biomed Inform*, vol. 125, p. 103957, 2022, doi: <https://doi.org/10.1016/j.jbi.2021.103957>.
- [16] F. Zhuang *et al.*, "A Comprehensive Survey on Transfer Learning," Jun. 2020, [Online]. Available: <http://arxiv.org/abs/1911.02685>
- [17] J. A. Raj, L. Qian, and Z. M. Ibrahim, "Fine-tuning - a Transfer Learning approach," *ArXiv*, vol. abs/2411.03941, 2024, [Online]. Available: <https://api.semanticscholar.org/CorpusID:273850276>
- [18] Ž. Đ. Vujovic, "Classification Model Evaluation Metrics," *International Journal of Advanced Computer Science and Applications*, vol. 12, no. 6, 2021, doi: 10.14569/IJACSA.2021.0120670.
- [19] S. Sathyanarayanan, "Confusion Matrix-Based Performance Evaluation Metrics," *African Journal of Biomedical Research*, vol. 27, no. 4S, pp. 4023–4031, Nov. 2024, doi: 10.53555/ajbr.v27i4s.4345.
- [20] S. E. Arman, Md. A. B. Bhuiyan, H. M. Abdullah, S. Islam, T. T. Chowdhury, and Md. A. Hossain, "BananaLSD: A banana leaf images dataset for classification of banana leaf diseases using machine learning," *Data Brief*, vol. 50, p. 109608, 2023, doi: <https://doi.org/10.1016/j.dib.2023.109608>.
- [21] E. Medhi and N. Deb, "PSFD-Musa: A dataset of banana plant, stem, fruit, leaf, and disease," *Data Brief*, vol. 43, p. 108427, 2022, doi: <https://doi.org/10.1016/j.dib.2022.108427>.
- [22] A. Aviles-Noriega, L. M. Serrato-Diaz, M. C. Giraldo-Zapata, H. E. Cuevas, and L. I. Rivera-Vargas, "The Sigatoka Disease Complex Caused by Pseudocercospora spp. and Other Fungal Pathogens Associated with Musa spp. in Puerto Rico," *Plant Dis*, vol. 108, no. 5, pp. 1320–1330, Nov. 2023, doi: 10.1094/PDIS-03-23-0433-RE.
- [23] Scikit-learn Developers, "API Reference: sklearn.utils.class_weight.compute_class_weight." Accessed: Dec. 17, 2025. [Online]. Available: https://scikit-learn.org/stable/modules/generated/sklearn.utils.class_weight.compute_class_weight.html
- [24] H. Li, G. K. Rajbahadur, D. Lin, C.-P. Bezemer, and Z. M. Jiang, "Keeping Deep Learning Models in Check: A History-Based Approach to Mitigate Overfitting," *IEEE Access*, vol. 12, pp. 70676–70689, 2024, doi: 10.1109/access.2024.3402543.