

Perbandingan Kinerja Model DenseNet121, EfficientNetB0, dan MobileNetV1 untuk Klasifikasi Penyakit Daun Tebu

Krisnawan¹, Dr. Ir. Mohammad Idhom, S.P., S.Kom., M.T.², Alfian Rizaldy Pratama,
S.Tr.T., M.Tr.Kom.³

¹Sains Data, Universitas Pembangunan Nasional "Veteran" Jawa Timur

¹22083010068@student.upnjatim.ac.id

²alfan.rizaldy.fasilkom@upnjatim.ac.id

Corresponding author email: idhom@upnjatim.ac.id

ABSTRAK

Penyakit daun tebu merupakan salah satu faktor utama penyebab penurunan produktivitas tanaman tebu, sehingga deteksi dini menjadi langkah penting dalam pengendalian penyakit pada daun tebu. Deep learning berbasis citra digital menawarkan solusi diagnosis yang cepat dan akurat. Namun, arsitektur Convolutional Neural network berukuran besar seperti VGG16 dan ResNet50 kurang efisien serta berpotensi mengalami overfitting pada dataset terbatas. Penelitian ini mengevaluasi tiga arsitektur CNN modern, yaitu DenseNet121, EfficientNetB0, dan MobileNetV1, untuk klasifikasi lima kelas penyakit daun tebu menggunakan 2.521 citra dataset sekunder. Seluruh model dilatih dengan konfigurasi pelatihan yang seragam untuk memastikan objektivitas evaluasi. Hasil penelitian menunjukkan bahwa DenseNet121 menghasilkan akurasi validasi tertinggi sebesar 92% dengan waktu pelatihan 167.220 detik, EfficientNetB0 mencapai akurasi 88% dengan waktu pelatihan 108.480 detik, sedangkan MobileNetV1 memperoleh akurasi 87% dengan waktu pelatihan tercepat yaitu 100.260 detik. Temuan ini menunjukkan bahwa pemilihan arsitektur pada sistem deteksi penyakit daun tebu perlu mempertimbangkan keseimbangan antara akurasi dan efisiensi komputasi, sehingga model dapat diterapkan secara optimal pada kebutuhan diagnosis cepat dan aplikatif di lingkungan pertanian.

Keywords: DenseNet121, EfficientNetB0, Klasifikasi, MobileNetv1, Penyakit Daun Tebu

I. PENDAHULUAN (10PT)

Indonesia dikenal sebagai negara agraris dengan sektor pertanian yang memegang peranan penting dalam penyerapan tenaga kerja nasional. Berdasarkan laporan yang dirilis Kementerian Pertanian, pada Februari 2025 sektor pertanian tercatat sebagai lapangan usaha dengan serapan tenaga kerja terbesar, yaitu 26,75% dari total angkatan kerja nasional [1]. Selain itu, subsektor Pertanian, Kehutanan, dan Perikanan berkontribusi sebesar 9,25% terhadap Produk Domestik Bruto (PDB) Indonesia pada tahun 2022. Dalam subsektor perkebunan, tebu menjadi komoditas strategis karena merupakan bahan baku utama industri gula nasional [2]. Pemerintah menargetkan perluasan areal tanam tebu hingga 100.453 hektare pada tahun 2025 untuk memperkuat ketahanan gula nasional [3]. Namun, produktivitas tebu seringkali terhambat oleh serangan penyakit tanaman yang dapat menurunkan hasil panen secara drastis [4]. Kondisi ini menegaskan perlunya sistem identifikasi penyakit yang cepat, akurat, dan efisien untuk mendukung produktivitas tebu di tingkat lapangan.

Perkembangan teknologi kecerdasan buatan, khususnya *Deep Learning*, menghadirkan solusi efektif dalam analisis citra pertanian. *Convolutional Neural*

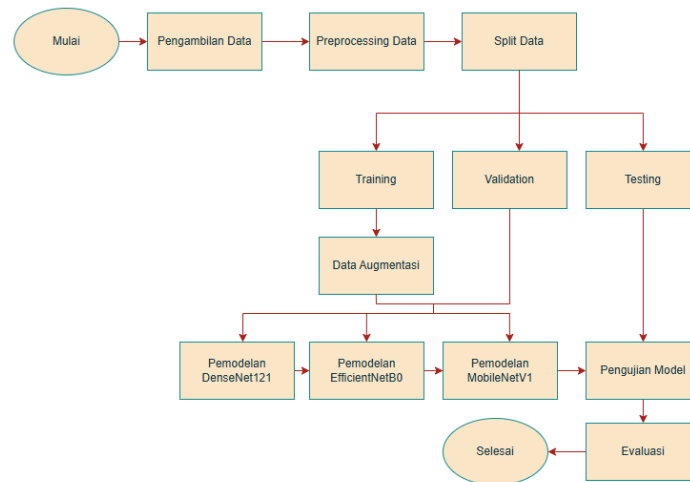
Network (CNN) mampu mengekstraksi fitur visual yang kompleks seperti pola tekstur, tepi, dan bentuk secara otomatis, sehingga sangat sesuai untuk klasifikasi penyakit tanaman [5]. VGG-16 merupakan salah satu arsitektur CNN yang banyak digunakan karena konsistensi kernel 3×3 pada setiap lapisannya, tetapi model ini memiliki jumlah parameter yang sangat besar sehingga membutuhkan komputasi tinggi dan kurang efisien ketika diterapkan pada dataset terbatas [6]. ResNet-50 menawarkan *residual connections* yang efektif dalam mengatasi *vanishing gradient*, tetapi kedalaman dan kompleksitas jaringannya menjadikan model ini rentan mengalami *overfitting* pada dataset berukuran kecil [7].

Keterbatasan tersebut mendorong pengembangan arsitektur CNN yang lebih efisien seperti DenseNet121, EfficientNetB0, dan MobileNetV1. DenseNet121 memanfaatkan mekanisme *feature reuse* yang memungkinkan propagasi informasi lebih baik, dan penelitian oleh Adi Dwifana, et al., menunjukkan bahwa DenseNet121 mencapai akurasi hingga 94% pada klasifikasi penyakit daun padi, sedangkan DenseNet169 dan DenseNet201 masing-masing mencapai 89% dan 92% [8]. Penelitian lain oleh Siti Zulaikha, et al., menggunakan MobileNetV1 menggunakan *depthwise separable convolution* yang menjadikannya lebih ringan dan tetap akurat, dengan performa mencapai 95,62% pada klasifikasi penyakit daun tomat [9]. Peneliti Alfataniah Nur. F., et al., menggunakan EfficientNetB0 memanfaatkan struktur *compound scaling* yang mengoptimalkan kedalaman, lebar, dan resolusi jaringan secara seimbang, dengan akurasi sebesar 95,70% pada klasifikasi penyakit tanaman kulit [10].

Berdasarkan penelitian terdahulu, arsitektur seperti DenseNet121, MobileNetV1, dan EfficientNetB0 telah menunjukkan kemampuan yang handal dalam melakukan klasifikasi citra, baik dalam studi penyakit tanaman maupun citra medis. Temuan ini mengindikasikan bahwa ketiga model tersebut memiliki potensi kuat untuk diterapkan pada identifikasi penyakit daun tebu. Meskipun demikian, setiap arsitektur memiliki karakteristik jaringan yang berbeda, seperti cara pemanfaatan fitur, tingkat efisiensi komputasi, dan strategi penskalaan yang digunakan. Perbedaan ini menimbulkan kebutuhan untuk melakukan kajian komparatif guna memahami sejauh mana performa masing-masing model dapat menyesuaikan diri dengan karakteristik visual penyakit pada daun tebu. Oleh karena itu, penelitian ini dilakukan untuk menganalisis dan membandingkan performa DenseNet121, EfficientNetB0, dan MobileNetV1 dalam klasifikasi penyakit daun tebu melalui evaluasi akurasi, jumlah parameter, dan efisiensi komputasi. Penelitian ini diharapkan mampu memberikan dasar ilmiah dalam pemilihan arsitektur yang tepat untuk deteksi penyakit daun secara cepat, akurat, dan aplikatif di lingkungan pertanian berbasis lapangan, serta mendukung pengembangan sistem diagnosis berbasis citra pada konteks lain di masa mendatang.

II. METODOLOGI PENELITIAN

Pendekatan *deep learning* berbasis *Convolutional Neural Network* (CNN) digunakan pada penelitian ini karena CNN mampu mempelajari pola visual, tekstur, dan variasi warna pada citra daun tebu secara otomatis sehingga efektif untuk tugas klasifikasi penyakit tanaman [11]. Dalam penelitian ini akan dijelaskan tahapan keseluruhan penelitian pada Gambar 1.




Gambar 1. Diagram Alur Penelitian





Alur penelitian dimulai dari pengambilan data citra daun tebu, kemudian diproses melalui tahap *preprocessing* untuk menstandarkan ukuran dan format citra. Setelah itu, data dibagi menjadi tiga bagian, yaitu *training*, *validation*, dan *testing*. Pada tahap *training* dilakukan augmentasi data untuk menambah variasi citra dan mengurangi risiko *overfitting*. Data yang telah diproses kemudian digunakan dalam pemodelan menggunakan tiga arsitektur berbeda, yaitu DenseNet121, EfficientNetB0, dan MobileNetV1. Seluruh model yang telah dilatih selanjutnya diuji menggunakan data *testing*, kemudian hasil pengujian dievaluasi untuk membandingkan akurasi, efisiensi komputasi, serta performa masing-masing model dalam klasifikasi penyakit daun tebu.

2.1 Pengambilan Data

Dataset yang digunakan dalam penelitian ini merupakan dataset sekunder, yaitu data yang telah tersedia sebelumnya sehingga tidak melalui proses akuisisi langsung di lapangan. Penelitian ini menggunakan *Sugarcane Leaf Disease Dataset* dari Daphal dan Koli tahun 2022 dengan total 2.521 citra daun tebu yang terbagi ke dalam lima kelas penyakit, yaitu *Healthy*, *Mosaic*, *RedRot*, *Rust*, dan *Yellow*. Setiap citra berupa gambar RGB (Red, Green, Blue) yang berfungsi sebagai variabel bebas atau input untuk diekstraksi oleh model *deep learning*, sedangkan variabel terikat adalah label kelas penyakit daun tebu sebagai target klasifikasi [12]. Berikut ini adalah distribusi jumlah citra pada masing-masing kelas pada Tabel 1.

Tabel 1. Distribusi Dataset Penyakit Daun Tebu

	Label Penyakit	Citra Penyakit	Jumlah Citra	Keterangan
1	Healthy		522	Daun sehat tanpa gejala penyakit

2	Mosaic		462	Pola bercak mosaic atau garis putih samar tidak beraturan yang disebabkan <i>Sugarcane Mosaic Virus</i>
3	Yellow		505	Daun menguning akibat infeksi <i>Sugarcane Yellow Leaf Virus</i>
4	Redrot		518	Perubahan warna merah kecoklatan di tengah tangkai daun akibat infeksi jamur <i>Colletotrichum falcatum</i>
5	Rust		514	Bercak oranye/coklat akibat penyakit karat disebabkan jamur <i>Puccinia melanocephala</i>
Total			2521	

Berdasarkan tabel tersebut, distribusi jumlah citra pada setiap kelas relatif seimbang dengan rentang 462 hingga 522 citra per kelas. Kondisi ini penting karena mengurangi potensi ketidakseimbangan data yang dapat membuat model bias terhadap kelas tertentu. Kelas *Healthy* memiliki jumlah citra terbesar yaitu 522, sedangkan *Mosaic* merupakan kelas dengan citra paling sedikit yaitu 462. Adapun *RedRot*, *Rust*, dan *Yellow* memiliki jumlah data yang hampir seragam sehingga mendukung proses pelatihan model yang stabil.

2.2 Preprocessing Data

Preprocessing data merupakan tahap pengolahan awal untuk menyiapkan citra agar sesuai dengan format input model *deep learning*. Tahap ini bertujuan untuk menyeragamkan data, mengurangi ketidakkonsistenan, serta meningkatkan stabilitas pelatihan dan kualitas hasil klasifikasi. Pada penelitian ini, citra daun tebu dalam dataset sekunder memiliki resolusi tinggi yang tidak seragam, yaitu 3120×4160 piksel dalam format RGB, sehingga tidak dapat langsung digunakan sebagai input model. Seluruh citra kemudian dilakukan *resize* menjadi 224×224 piksel dengan tiga kanal warna $224 \times 224 \times 3$ agar sesuai dengan kebutuhan DenseNet121, EfficientNetB0, dan MobileNetV1. Proses ini mengubah dimensi tanpa memodifikasi rentang intensitas piksel 0-255, sehingga citra memiliki format tensor yang seragam dan siap digunakan pada tahap pelatihan, validasi, serta pengujian model.

2.3 Split Data

Pembagian dataset dilakukan untuk memisahkan *data training*, *validation*, dan *testing* agar proses pelatihan model berlangsung secara objektif dan tidak terjadi kebocoran data. Dataset dibagi ke dalam tiga subset dengan proporsi 80% untuk *data training*, 10% untuk *data validation*, dan 10% untuk *data testing*. Proporsi ini dipilih agar data latih tetap cukup besar sehingga model mampu mempelajari pola penyakit secara optimal, sementara data *validation* digunakan untuk memantau kinerja model selama pelatihan dan *data testing* dimanfaatkan untuk menilai performa akhir pada citra yang belum pernah dilihat sebelumnya. Pembagian dilakukan secara acak pada setiap kelas penyakit dengan *random seed* sebesar 42 untuk memastikan hasil pemisahan konsisten dan dapat direproduksi. Berikut adalah proporsi data setelah proses pembagian dilakukan:

Tabel 2. Proporsi Pembagian Data

No	Data	Nilai Parameter
1	<i>Training</i>	80%
2	<i>Validation</i>	10%
3	<i>Testing</i>	10%

2.4 Augmentasi Data

Augmentasi data digunakan untuk menambah variasi citra latih agar model tidak hanya belajar dari pola yang sama, sekaligus mencegah *overfitting* dan meningkatkan kemampuan generalisasi terhadap kondisi visual daun tebu yang beragam. Teknik augmentasi yang diterapkan ditunjukkan pada Tabel 3.

Tabel 3. Teknik Augmentasi

No	Teknik Augmentasi	Nilai Parameter
1	Rotasi	15°
2	Width Shift	10%
3	Height Shift	10%
4	Zoom Range	10%
5	Horizontal Flip	True
6	Fill Mode	Nearest


Seluruh teknik augmentasi diterapkan secara acak saat batch citra diproses sehingga setiap *epoch* menghasilkan variasi baru dari data latih. Pendekatan ini membuat model lebih *robust* dalam mengenali pola penyakit pada citra daun tebu meskipun terjadi perubahan arah, posisi, atau skala pada sampel di lapangan.

2.5 Pemodelan

Penelitian ini menggunakan 3 model terbaru dari CNN yaitu, DenseNet121, EfficientNetB0, dan MobileNetV1. Berikut adalah penjelasan masing-masing model, dan arsitektur yang digunakan sebagai tahap penelitian.

2.5.1. DenseNet121

Dense Convolutional Network atau DenseNet merupakan arsitektur jaringan konvolusional yang menghubungkan setiap layer dengan semua layer setelahnya melalui mekanisme *dense connectivity*. Setiap layer menerima input berupa fitur gabungan dari seluruh layer sebelumnya dan meneruskan hasilnya ke seluruh layer berikutnya. Berbeda dengan CNN konvensional yang hanya memiliki koneksi ke layer selanjutnya, DenseNet dengan L layer memiliki koneksi langsung sejumlah $L(L + 1)/2$, sehingga memungkinkan propagasi fitur yang lebih kaya. Pendekatan ini meringankan permasalahan *vanishing gradient*, meningkatkan pemanfaatan kembali fitur, serta mengurangi kebutuhan parameter model secara signifikan [13].




Gambar 2. Arsitektur DenseNet121

Pada penelitian ini digunakan arsitektur DenseNet121, yang terdiri dari empat *dense block* dengan jumlah lapisan bertingkat, yaitu 6, 12, 24, dan 16 lapisan konvolusi. Model diawali dengan konvolusi 7x7 dengan *stride 2* yang diikuti *Batch Normalization*, *ReLU*, dan *MaxPooling*, sebelum memasuki *dense block* pertama. Di dalam setiap *dense block*, output dari setiap *layer* dikonkatenasi sebagai *input layer* berikutnya sehingga representasi fitur terus bertambah tanpa menghilangkan informasi dari lapisan awal. Setelah proses struktur *dense block* disisipkan *transition layer* yang terdiri dari konvolusi 1x1 dan *average pooling* untuk menurunkan jumlah kanal dan resolusi fitur, menjaga efisiensi komputasi. Setelah blok terakhir, fitur global diringkas melalui *Global Average Pooling* dan diteruskan ke *lapisan Dense* berukuran 512 dan 256 dengan *ReLU* serta *Dropout* untuk mencegah *overfitting*, sebelum akhirnya diprediksi melalui *lapisan Softmax* sesuai jumlah kelas penyakit daun tebu.

2.5.2. EfficientNetB0

EfficientNet-B0 merupakan salah satu varian dari arsitektur EfficientNet yang dirancang oleh tim riset Google AI untuk menghasilkan jaringan saraf yang lebih efisien secara komputasi, tetapi tetap mampu mempertahankan performa yang tinggi. Arsitektur EfficientNet memanfaatkan pendekatan *smart scaling*, yaitu peningkatan kedalaman, lebar, dan resolusi model secara proporsional untuk mencapai keseimbangan optimal antara efisiensi dan kinerja [14].




Gambar 3. Arsitektur EfficientNetB0

Implementasi EfficientNet-B0 pada penelitian ini diawali dengan tahap *rescaling* untuk menormalisasi data citra, kemudian dilanjutkan konvolusi 3×3 dengan *stride* 2 yang menghasilkan 32 *feature map*, diikuti *Batch Normalization* dan fungsi aktivasi. Setelah itu, jaringan terdiri dari rangkaian blok *Mobile Inverted Bottleneck Convolution* (MBConv) yang merupakan inti arsitektur EfficientNet, dengan konfigurasi berlapis: MBConv1 menghasilkan 16 kanal, diikuti MBConv6 dengan *stride* 2 untuk menurunkan resolusi spasial menjadi 56×56 dan 24 kanal, kemudian blok MBConv6 berikutnya meningkatkan jumlah kanal secara bertahap hingga 320 sambil mempertahankan efisiensi parameter. Struktur MBConv6 mengombinasikan *depthwise convolution* 3×3, *pointwise convolution* 1×1, dan mekanisme *inverted residual*, sehingga fitur dari lapisan awal tetap dipertahankan saat transformasi dimensi dilakukan. Setelah blok terakhir, konvolusi 1×1 menghasilkan 1.280 kanal sebelum fitur diringkas melalui *Global Average Pooling*, dan diteruskan ke lapisan *Dense* 512 dan 256 dengan aktivasi *ReLU* serta *dropout* untuk mencegah *overfitting*. Lapisan *Softmax* pada bagian akhir memproyeksikan representasi fitur ke dalam lima kelas penyakit daun tebu dengan menghasilkan probabilitas prediksi.

2.5.3. MobileNetV1

MobileNet merupakan arsitektur CNN yang dirancang untuk kebutuhan komputasi rendah, sehingga cocok digunakan pada perangkat seluler, *embedded system*, atau sistem tanpa *Graphics Processing Unit* (GPU). Model ini mengorbankan sedikit akurasi untuk memperoleh efisiensi, dengan memanfaatkan *Depthwise Separable Convolution* (DSC) sebagai pengganti konvolusi standar. Arsitektur MobileNet tersusun dari sepuluh blok, di mana blok pertama menggunakan konvolusi biasa menghasilkan 32 fitur, sementara blok selanjutnya menerapkan DSC dan *down-sampling* hingga menghasilkan 1024 fitur pada blok terakhir [15].



Gambar 4. Arsitektur MobileNetV1

Arsitektur MobileNetV1 dibangun menggunakan *Depthwise Separable Convolution*, yaitu pemisahan konvolusi standar menjadi *depthwise convolution* 3×3 untuk memproses tiap kanal secara terpisah dan *pointwise convolution* 1×1 untuk menggabungkan hasilnya, sehingga kompleksitas komputasi berkurang signifikan. Setelah konvolusi awal 3×3 dengan *stride* 2 yang menghasilkan 32 fitur, model menjalankan blok DSC bertahap dengan variasi *stride* untuk menurunkan resolusi spasial sambil meningkatkan jumlah kanal hingga 1024 di layer akhir. Representasi fitur kemudian diringkas melalui *Global Average Pooling* dan diteruskan ke lapisan *Dense* dengan aktivasi *ReLU* serta *Dropout*, sebelum akhirnya diklasifikasikan melalui *Softmax* untuk klasifikasi sesuai jumlah kelas.

2.6 Evaluasi

Evaluasi performa model dalam mengklasifikasikan lima kelas penyakit daun tebu dilakukan menggunakan *confusion matrix*, yang membandingkan hasil prediksi dengan label sebenarnya melalui nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Berdasarkan nilai tersebut dihitung akurasi, presisi, recall, dan F1-score sebagai dasar perbandingan untuk menentukan model yang paling akurat dalam mengenali kelas *Healthy*, *Mosaic*, *RedRot*, *Rust*, dan *Yellow*. Rumus masing-masing metrik ditunjukkan sebagai berikut:

Beberapa parameter untuk menilai performa sistem yang dianalisis dalam penelitian ini, antara lain:

2.6.1. Accuracy

Accuracy merupakan indikator tingkat ketepatan sistem dalam mengklasifikasikan input sehingga menghasilkan output yang sesuai dengan kelas yang benar. Berikut adalah persamaan untuk menghitung nilai akurasi:

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

2.6.2. Precision

Precision merupakan indikator ketepatan prediksi positif yang benar dibandingkan dengan keseluruhan prediksi positif yang dihasilkan oleh sistem. Nilai presisi dapat dihitung menggunakan persamaan berikut:

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

2.6.3. Recall

Recall atau sensitivitas merupakan indikator kemampuan sistem dalam mengidentifikasi prediksi positif yang benar dibandingkan dengan keseluruhan data positif yang sebenarnya. Perhitungan nilai *recall* dapat dilihat pada persamaan berikut:

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

2.6.4. F1-Score

F1-Score merupakan metrik yang mengombinasikan nilai *precision* dan *recall* dengan memperhitungkan *false positive* serta *false negative*. Persamaan untuk menghitung *F1-Score* sebagai berikut:

$$F1 - Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \quad (4)$$

2.6.5. Loss

Parameter *loss* merepresentasikan tingkat kesalahan model dalam melakukan prediksi saat mengklasifikasikan suatu input.

III. HASIL DAN ANALISIS

Bagian ini menyajikan hasil pengujian tiga arsitektur *deep learning*, yaitu DenseNet121, EfficientNetB0, dan MobileNetV1 dalam klasifikasi lima kelas penyakit daun tebu. Untuk memastikan perbandingan yang adil, seluruh model dilatih menggunakan konfigurasi pelatihan yang sama sehingga performa yang diperoleh mencerminkan kemampuan arsitektur masing-masing. Parameter pelatihan yang digunakan ditunjukkan pada Tabel 4.

Tabel 4. Konfigurasi Tiap Model

Komponen	DenseNet121	EfficientNetB0	MobileNetV1
Input Size	224x224x3	224x224x3	224x224x3
Batch Size	32	32	32
Epoch	20	20	20
Optimizer	Adam	Adam	Adam
Loss Function	Categorical CrossEntropy	Categorical CrossEntropy	Categorical CrossEntropy
Learning Rate	0,00001	0,00001	0,00001
Jumlah Parameter	± 7,978,856	± 5,330,564	± 4,253,864
Custom Layer	Global Average Pooling, Dropout & Dense	Global Average Pooling & Dense	Global Average Pooling & Dense
Fungsi Aktivasi	Softmax	Softmax	Softmax

Tabel 4 memperlihatkan bahwa seluruh model menggunakan konfigurasi pelatihan yang konsisten, sehingga proses evaluasi dilakukan dalam kondisi yang setara. Perbedaan utama terletak pada kompleksitas arsitektur. DenseNet121 memiliki parameter paling besar sehingga memungkinkan ekstraksi fitur yang lebih kaya. EfficientNetB0 berada pada tingkat menengah dengan pendekatan *compound scaling* untuk efisiensi. MobileNetV1 memiliki parameter paling sedikit karena menggunakan *depthwise separable convolution* sehingga lebih ringan secara komputasi.

Tabel 5. Perbandingan Pelatihan Model

Model	Akurasi Pelatihan	Akurasi Validasi	Loss Pelatihan	Loss Validasi	Waktu /detik
DenseNet121	0,9688	0,9286	0,2305	0,2039	167220
EfficientNetB0	0,9255	0,8720	0,2685	0,3609	108480
MobileNetV1	0,9193	0,8800	0,2481	0,3660	100260

Tabel 5 menunjukkan bahwa model DenseNet121 memberikan performa terbaik dengan akurasi pelatihan dan validasi tertinggi serta nilai loss validasi terendah. Hal ini menunjukkan bahwa struktur *dense connectivity* mampu menjaga aliran gradien antar *layer* sehingga fitur visual penyakit dapat ditangkap lebih efektif. Namun, tingginya jumlah parameter menyebabkan waktu pelatihan paling lama.

EfficientNetB0 memiliki performa menengah. Akurasi validasi lebih rendah dibanding DenseNet121, tetapi tetap stabil. Pendekatan *compound scaling* membuat model efisien, meskipun ekstraksi fitur tidak sedalam DenseNet121. MobileNetV1 merupakan model paling cepat dilatih karena arsitektur *depthwise separable convolution* yang ringan, tetapi generalisasinya sedikit menurun pada validasi. Untuk memahami karakteristik performa model secara lebih detail pada tiap kategori penyakit daun tebu, disajikan perbandingan metrik evaluasi tiap kelas pada Tabel berikut.

Tabel 6. Perbandingan Performa Model pada Tiap Kelas Penyakit

Kelas	Model	Precision	Recall	F1-Score
Healthy	DenseNet121	0,83	0,98	0,90
	EfficientNetB0	0,76	0,98	0,86
	MobileNetV1	0,73	0,98	0,84
Mosaic	DenseNet121	0,95	0,81	0,87
	EfficientNetB0	0,96	0,53	0,68
	MobileNetV1	0,97	0,68	0,80
RedRot	DenseNet121	0,91	1,00	0,95
	EfficientNetB0	0,96	0,98	0,97
	MobileNetV1	0,89	0,92	0,91
Rust	DenseNet121	0,96	0,96	0,96
	EfficientNetB0	0,86	0,94	0,90
	MobileNetV1	0,96	0,90	0,93
Yellow	DenseNet121	0,98	0,82	0,89
	EfficientNetB0	0,94	0,94	0,94
	MobileNetV1	0,90	0,84	0,87

Tabel evaluasi setiap kelas penyakit daun tebu menunjukkan bahwa DenseNet121 memiliki performa paling stabil pada sebagian besar kategori penyakit. Model ini memperoleh *f1-score* tertinggi pada *RedRot* dan *Rust* sebesar 0,95 dan 0,96 yang memiliki ciri visual kuat berupa perubahan warna merah kecoklatan pada tangkai dan bercak karat kontras. Arsitektur dengan *dense connectivity* memungkinkan *reuse* fitur antar *layer* sehingga menangkap pola tekstur lokal maupun global secara efektif. Pada kelas *Mosaic*, *f1-score* 0,87 menunjukkan bahwa DenseNet121 tetap mampu mengidentifikasi pola bercak tidak beraturan yang relatif sulit dibedakan oleh model lain.

EfficientNetB0 menunjukkan performa yang tidak merata antar kelas. Model ini unggul pada kelas *Yellow* dengan *f1-score* 0,94 karena gejala menguning memiliki perubahan warna yang dominan secara global dan mudah terpisah dari daun sehat. Namun, performanya menurun signifikan pada kelas *Mosaic* yaitu *f1-score* 0,68 akibat keterbatasan jaringan dalam menangkap variasi patch kecil yang membutuhkan pemodelan multi-skala. Pendekatan *compound scaling* meningkatkan efisiensi parameter, tetapi tidak cukup untuk mengekstraksi detail tekstur halus seperti pola *Mosaic*.

MobileNetV1 menghasilkan performa yang relatif seimbang, tetapi secara umum berada sedikit di bawah DenseNet121. Model ini mencapai *f1-score* tinggi pada kelas *RedRot* 0,91 dan *Rust* 0,93. Hal ini menunjukkan efektivitas *depthwise separable convolution* dalam menangkap bentuk dan tekstur dasar. Namun, performanya lebih rendah pada kelas dengan visual kompleks seperti *Yellow* sebesar 0,87 dan *Mosaic* 0,80, sehingga mengindikasikan adanya keterbatasan representasi fitur akibat kedalaman arsitektur yang lebih ringan.


Tabel 7. Perbandingan Metrik Global

Model	Accuracy	Macro Avg	Weighted Avg
DenseNet121	0,92	0,92	0,92
EfficientNetB0	0,88	0,87	0,88
MobileNetV1	0,87	0,87	0,87

Tabel metrik di atas mendukung temuan analisis per kelas penyakit daun tebu. DenseNet121 memperoleh nilai akurasi, *macro average*, dan *weighted average* terbaik


yaitu 0,92, yang menandakan performa seimbang di seluruh label tanpa bias terhadap kelas tertentu. EfficientNetB0 memiliki akurasi 0,88 dan macro average 0,87, menunjukkan generalisasi cukup baik namun sensitif terhadap kelas berpola kompleks. MobileNetV1 menghasilkan akurasi 0,87 dengan rata-rata makro yang sama, menandakan konsistensi performa, tetapi dengan batasan akurasi akibat desain model yang mengutamakan efisiensi komputasi dibanding kedalaman ekstraksi fitur.

Meskipun metrik global menunjukkan perbedaan performa yang jelas antar model, nilai akurasi maupun *f1-score* belum menggambarkan arah kesalahan yang terjadi pada setiap kelas. Untuk memahami pola kesalahan klasifikasi dan kemampuan model membedakan gejala penyakit daun tebu, analisis dilakukan menggunakan *confusion matrix*. Visualisasi ini menunjukkan seberapa banyak sampel tiap kelas diprediksi dengan benar, serta kelas apa yang menjadi sumber kesalahan terbesar. Berikut pembahasan *confusion matrix* untuk setiap arsitektur model.



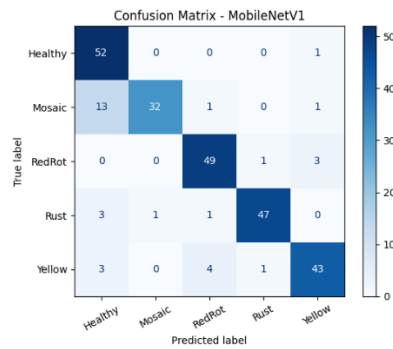
Gambar 5. Confusion Matrix DenseNet121

Hasil *confusion matrix* DenseNet121 menunjukkan kinerja yang sangat baik pada sebagian besar kelas. Kelas *RedRot*, *Rust*, dan *Healthy* hampir tidak mengalami kesalahan, masing-masing diklasifikasikan dengan benar. Kesalahan terbesar terjadi pada kelas *Mosaic*, yaitu 8 citra diklasifikasikan sebagai *Healthy*. Hal ini menunjukkan bahwa ciri visual bercak *Mosaic* yang tidak teratur memiliki kemiripan tekstur dengan daun sehat. Kelas *Yellow* juga menunjukkan kesalahan minor dengan 3 sampel diprediksi sebagai *Healthy*. Hal ini menunjukkan kecenderungan model untuk mengasumsikan daun normal ketika perubahan warna masih berada pada fase awal.



Gambar 6. Confusion Matrix EfficientNetB0

Hasil *confusion matrix* EfficientNetB0 menunjukkan pola kesalahan yang lebih kuat dibanding DenseNet121. Kesalahan terbesar terjadi pada kelas *Mosaic*, yaitu 15 sampel *Mosaic* diprediksi sebagai *Healthy*. Hal ini selaras dengan nilai *recall* rendah pada kelas tersebut, karena pola *Mosaic* memiliki tekstur halus yang sulit dibedakan dari daun tanpa penyakit. Kelas *Rust* juga memiliki kesalahan moderat, dengan 5 sampel diprediksi sebagai *Healthy*. Hal ini menunjukkan bahwa EfficientNet cenderung memprioritaskan ciri warna global daripada bercak tekstur lokal. Meski demikian, kelas *RedRot* tetap dominan benar, dan menandakan fitur visual penyakit ini relatif mudah dideteksi oleh model.



Gambar 7. Confusion Matrix MobileNetV1

Hasil *confusion matrix* MobileNetV1 memiliki jumlah kesalahan yang lebih menyebar dibanding dua model sebelumnya. Kesalahan terbesar kembali terjadi pada kelas *Mosaic*, yaitu 13 sampel diprediksi sebagai *Healthy* dan 1 sampel diprediksi sebagai *RedRot*. Hal ini menandakan bahwa representasi fitur ringan pada MobileNet tidak cukup menangkap variasi tekstur *Mosaic*. Pada kelas *Rust*, model menghasilkan 3 kesalahan ke *Healthy* dan 1 ke *RedRot*. Kinerja kelas *Healthy* tetap kuat dengan 52 label benar. Hal ini menunjukkan model mampu mengenali daun normal dengan baik meskipun kapasitas arsitekturnya terbatas.

IV. KESIMPULAN

Penelitian ini membandingkan tiga arsitektur *deep learning* modern DenseNet121, EfficientNetB0, dan MobileNetV1 untuk klasifikasi penyakit daun tebu berbasis citra digital. Hasil evaluasi menunjukkan bahwa DenseNet121 memberikan performa terbaik dengan akurasi validasi sebesar 92%, serta F1-score tertinggi dan stabil pada sebagian besar kelas penyakit. Struktur *dense connectivity* yang dimiliki model ini memungkinkan propagasi fitur yang lebih efektif dan mencegah *vanishing gradient*, sehingga meningkatkan akurasi deteksi gejala penyakit daun tebu.

Model EfficientNetB0 menunjukkan keseimbangan antara efisiensi dan akurasi dengan nilai akurasi 88%, sementara MobileNetV1 unggul dalam efisiensi waktu pelatihan dan cocok diterapkan pada sistem berdaya komputasi rendah. Dengan demikian, dapat disimpulkan bahwa DenseNet121 merupakan arsitektur yang memiliki tingkat akurasi paling baik, sedangkan model yang paling optimal dari segi waktu dan akurasi adalah EfficientNetB0, serta MobileNetV1 dapat menjadi alternatif efisien pada aplikasi dengan keterbatasan sumber daya seperti *mobile*.

Penelitian ini memberikan kontribusi penting dalam pengembangan sistem deteksi penyakit tanaman berbasis *deep learning* yang cepat, akurat, dan aplikatif untuk mendukung peningkatan produktivitas sektor pertanian, khususnya pada komoditas tebu.

REFERENSI

- [1] K. Pertanian, *Statistik Tenaga Kerja Semester I 2025*, " Satu Data Pertanian, 2025. [Online]. Available: https://satudata.pertanian.go.id/assets/docs/publikasi/Statistik_Tenaga_Kerja_Semester_I_2025.pdf
- [2] K. Pertanian, *Statistik Makro Sektor Pertanian Tahun 2024*. [Online]. Available: <https://satudata.pertanian.go.id/details/publikasi/661>
- [3] Agrofarm.co.id, "Kementan Targetkan Tahun 2025 Tambah Areal Tebu 100.453 Ha," 2025. [Online]. Available: <http://www.agrofarm.co.id/2025/11/kementan-targetkan-tahun-2025-tambah-areal-tebu-100-453-ha/>

- [4] Rahmad, "Uji Patogenitas Cendawan Pendeградasi Bahan Organik Pada Bibit Tanaman Tebu (*Saccharum officinarum*)," *Gastron. ecuatoriana y Tur. local.*, vol. 1, no. 69, pp. 5–24, 2021.
- [5] Pangestu, D. O. Q. Aziz, and C. Crys dian, "Klasifikasi Penyakit pada Tanaman Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network," *JISKA (Jurnal Inform. Sunan Kalijaga)*, vol. 10, pp. 235–248, 2025, doi: <https://doi.org/10.14421/jiska.2025.10.2.235-248>.
- [6] T. Anita and R. Ramadhani, "Analisis Perbandingan VGG-16 dan ResNet50 untuk Klasifikasi Multilabel Gambar Kerbau Toraja : Pendekatan Deep Learning," *J. Tek.*, vol. 22, no. 2, pp. 71–81, 2024, doi: <https://doi.org/10.37031/jt.v22i2.490>.
- [7] P. Y. Andrian, F. Bimantoro, and R. P. Rassy, "Comparative Analysis of ResNet-50 and VGG16 Architecture Accuracy in Garbage Classification System," *J. Comput. Sci. Informatics Eng.*, vol. 9, no. 1, pp. 43–51, 2025, doi: <https://doi.org/10.29303/jcosine.v8i1.620>.
- [8] A. D. Saputra, D. Hindarto, and H. Santoso, "Disease Classification on Rice Leaves using DenseNet121, DenseNet169, DenseNet201," *Sink. J. dan Penelit. Tek. Inform.*, vol. 7, no. 1, pp. 48–55, doi: <https://doi.org/10.33395/sinkron.v8i1.11906>.
- [9] S. Zulaikha, M. Zaki, M. A. Zulkifley, M. M. Stofa, and N. Azwan, "Classification of tomato leaf diseases using MobileNet V2," *IAES Int. J. Artif. Intell.*, vol. 9, no. 2, pp. 290–296, 2020, doi: <http://doi.org/10.11591/ijai.v9.i2.pp290-296>.
- [10] P. Khairunnisa, W. E. Putra, and W. Yitong, "Convolutional Neural Networks Using EfficientNetB0 Architecture and Hyperparameters on Skin Disease Classification," *Public Res. J. Eng. Data Technol. Comput. Sci.*, vol. 2, no. January, pp. 127–137, 2025, doi: <https://doi.org/10.57152/predatecs.v2i2.1569>.
- [11] D. Sutaji and H. Rosyid, "Convolutional Neural Network (CNN) Models for Crop Diseases Classification," *Kinet. Game Technol. Inf. Syst. Comput. Network, Comput. Electron. Control*, vol. 7, no. 2, pp. 155–166, 2022, doi: <https://doi.org/10.22219/kinetik.v7i2.1443>.
- [12] S. Daphal and S. Koli, "Sugarcane Leaf Disease Dataset," *Mendeley Data*, vol. 1, 2022, [Online]. Available: doi: 10.17632/9424skmnrk.1.
- [13] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, "Densely Connected Convolutional Networks," *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, 2017, doi: 10.1109/CVPR.2017.243.
- [14] A. N. Fajrina, Z. H. Pradana, S. I. Purnama, and S. Romadhona, "Penerapan Arsitektur EfficientNet-B0 Pada Klasifikasi Leukimia Tipe Acute Lymphoblastik Leukimia," *J. Ris. REKAYASA ELEKTRO*, vol. 6, no. 1, 2024, doi: <https://doi.org/10.30595/jrre.v6i1.22090>.
- [15] E. Prasetyo, R. Purbaningtyas, R. D. Adityo, N. Suciati, and C. Fatichah, "Combining MobileNetV1 and Depthwise Separable Convolution Bottleneck with Expansion for Classifying the Freshness of Fish Eyes," *Inf. Process. Agric.*, vol. 9, no. 4, pp. 478–489, 2022, doi: <https://doi.org/10.1016/j.inpa.2022.01.002>.