


Analisis Komparatif Arsitektur CNN untuk Klasifikasi Penyakit Daun Tebu Berbasis *Transfer Learning*

DOI: <http://dx.doi.org/10.35889/jutisi.v15i2.3431>

Creative Commons License 4.0 (CC BY – NC) 

Fakhrur Rofiq^{1*}, Achmad Noercholis²

Teknik Informatika, Institut Teknologi Dan Bisnis Asia Malang, Malang, Indonesia

*e-mail *Corresponding Author*: rofiqfariq@gmail.com

Abstract

Classifying sugarcane leaf diseases is critical in modern cultivation, because symptoms are often difficult to identify accurately through visual inspection alone. This study compares the performance of three Convolutional Neural Network (CNN) architectures Xception, EfficientNetB0, and ResNet50 using transfer learning on a dataset of 2,521 sugarcane leaf images grouped into five disease classes. A preprocessing stage, including image resizing, was applied to all samples. The data were then split into 80% training, 10% validation, and 10% testing sets. Each model was trained with the same training configuration to ensure a fair comparison, with consistent hyperparameters across experiments. Testing results indicate that EfficientNetB0 achieved the most stable performance with 99.5% accuracy, followed by ResNet50 at 98.2%, whereas Xception yielded the lowest performance due to training instability. These findings suggest that CNN architectures optimized via network-scaling efficiency better handle visual variability in sugarcane leaf disease images.

Keywords: *Sugarcane Leaf Disease; Transfer Learning; Xception; EfficientNetB0; ResNet50.*

Abstrak

Klasifikasi penyakit daun tebu sangat penting dalam praktik budidaya modern, karena gejala penyakit sering kali sulit diidentifikasi secara akurat hanya melalui pengamatan visual. Studi ini mengkomparasi kinerja tiga arsitektur *Convolutional Neural Network* (CNN), yaitu Xception, EfficientNetB0, dan ResNet50, menggunakan pendekatan *transfer learning* pada dataset 2.521 citra daun tebu yang dibagi ke dalam lima kelas penyakit. Tahap pra proses yang mencakup penyesuaian ukuran diterapkan pada seluruh citra. Selanjutnya, data dibagi menjadi 80% data pelatihan, 10% data validasi, dan 10% data pengujian. Setiap model dilatih menggunakan konfigurasi pelatihan yang seragam untuk memastikan perbandingan yang adil. Hasil pengujian menunjukkan bahwa EfficientNetB0 memiliki performa paling stabil dengan akurasi 99,5%, diikuti oleh ResNet50 dengan akurasi 98,2%, sedangkan Xception menunjukkan performa terendah akibat ketidakstabilan selama pelatihan. Temuan ini menunjukkan bahwa arsitektur CNN yang dioptimalkan melalui pendekatan efisiensi skala jaringan lebih mampu menangani variasi visual pada citra penyakit daun tebu.

Kata kunci: *Penyakit Daun Tebu; Transfer Learning; Xception; EfficientNetB0; ResNet50.*

1. Pendahuluan

Industri gula nasional menggunakan tanaman tebu sebagai komoditas strategis, dimana kesehatan daun yang berfungsi sebagai organ utama dalam proses fotosintesis sangat memengaruhi produktivitasnya Yulianti [1]. Bergantung pada varietas tebu, kondisi lingkungan, dan tingkat keparahan infeksi, penyakit pada daun tebu sering muncul dengan gejala yang mirip satu sama lain dalam praktik lapangan. Hal ini menunjukkan bahwa proses identifikasi penyakit secara manual tidak selalu konsisten dan sangat bergantung pada pengalaman pengamat. Kesalahan diagnosis awal dapat menyebabkan pengendalian yang terlambat, kualitas panen yang menurun, dan biaya produksi yang lebih tinggi. Situasi ini menunjukkan bahwa diperlukan

pendekatan diagnostik yang lebih sistematis, cepat, dan dapat diterapkan secara luas tanpa bergantung pada tenaga ahli.

Kemajuan teknologi dalam pengolahan citra digital membuka peluang baru untuk otomatisasi deteksi penyakit tanaman. Arsitektur *Convolutional Neural Network* (CNN) terbukti mampu menangkap pola visual yang kompleks seperti nekrosis dan perubahan pigmentasi yang sulit dilihat secara langsung. Dela Adelia et al [2] menegaskan bahwa CNN efektif dalam membedakan tekstur dan warna halus pada daun, sementara itu penggunaan *transfer learning* terbukti meningkatkan akurasi pada deteksi penyakit tomat Hasan et al [3]. Penelitian dari Mardiana dan Windari [4] menunjukkan bahwa arsitektur *EfficientNet* memiliki performa unggul dalam mengklasifikasikan berbagai penyakit jeruk.

Meskipun pemanfaatan *deep learning* berkembang pesat, penelitian khusus pada penyakit daun tebu masih terbatas. Penelitian oleh Amrulloh et al. [5] berfokus pada deteksi objek dengan YOLOv8, sedangkan penelitian oleh Firmansyah et al. [6] berfokus pada pengaruh learning rate terhadap performa model. Terdapat celah literatur di mana belum ada studi yang membandingkan berbagai arsitektur CNN secara langsung. Perbedaan teknik dan konfigurasi dalam eksperimen di penelitian sebelumnya membuat peneliti kesulitan untuk menentukan model mana yang paling unggul dan reliabel jika dihadapkan dengan kondisi yang sama.

Penelitian yang menggunakan CNN untuk mendeteksi penyakit tanaman telah menunjukkan kemajuan yang cukup besar. Menurut Hasan et al, penerapan pembelajaran transfer dapat meningkatkan ketepatan klasifikasi penyakit daun tomat karena model tidak perlu belajar fitur dasar dari awal. Agustiani et al, menemukan bahwa MobileNetV2 memberikan akurasi yang cukup baik pada komoditas tebu, tetapi pilihan arsitektur yang tepat sangat memengaruhi kinerja [7]. Pratitis et al, menggunakan CNN untuk penyakit bercak daun tebu dan memperoleh hasil yang bagus, menunjukkan bahwa CNN dapat digunakan pada dataset tebu dengan variasi visual yang tinggi [8]. Selain itu, untuk menemukan model deep learning terbaik, evaluasi komparatif yang menyeluruh diperlukan, seperti yang ditunjukkan oleh Bagchi et al. karena kinerja model dapat berbeda secara signifikan dari arsitektur ke arsitektur [9].

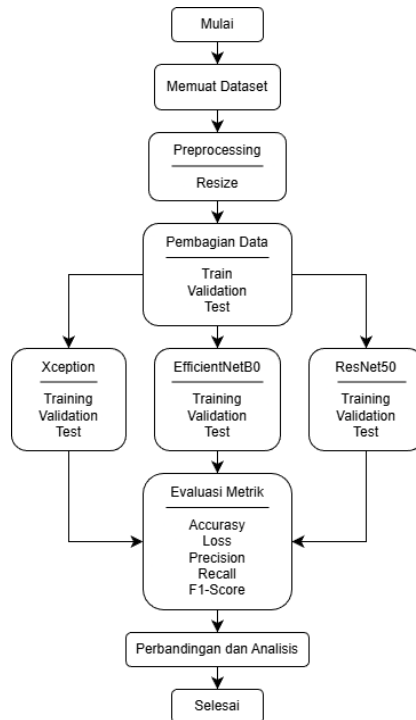
Menurut penelitian yang dilakukan oleh Aryadi dan Suhendar, Xception dapat dengan akurat mengklasifikasikan kematangan buah kelapa sawit, penyakit daun tanaman lain tampak kompleks secara visual [10] [8]. Namun, Ziliwu et al, menunjukkan bahwa TinyML bahkan dapat digunakan untuk klasifikasi berbasis model ringan, menunjukkan bahwa teknologi visi komputer dapat diterapkan pada berbagai situasi pertanian [11]. ResNet50 memasukkan konsep belajar residual, Arsitektur berbasis residual telah banyak diterapkan pada klasifikasi penyakit daun tanaman yang menunjukkan stabilitas pelatihan serta kemampuan generalisasi yang baik pada berbagai kondisi visual, yang membuatnya menjadi salah satu arsitektur CNN terbaik Kevin Santosa et al [12]. Dari situlah dalam bidang pertanian, transfer learning sangat penting, menurut Hossen et al [13]. Ini terutama berlaku dalam kasus di mana distribusi dataset tidak seimbang atau ukurannya relatif kecil. Secara keseluruhan, penelitian sebelumnya menunjukkan keandalan CNN, tetapi tidak membandingkan arsitektur dalam kondisi eksperimen yang sebanding.

Penelitian ini dilakukan evaluasi tiga arsitektur CNN populer, yaitu Xception, EfficientNetB0, dan ResNet50 dalam kondisi eksperimen yang identik. Ketiga model arsitektur tersebut dipilih berdasarkan filosofi desain yang berbeda. ResNet50 unggul dalam stabilitas gradien melalui *residual blocks*, Xception mengoptimalkan efisiensi melalui pemisahan campuran, dan EfficientNetB0 menawarkan performa yang seimbang. Penelitian ini menggunakan pendekatan *transfer learning* untuk mengklasifikasikan lima jenis penyakit tanaman tebu dengan tujuan memberikan landasan empiris yang kuat untuk membangun sistem deteksi penyakit daun tebu yang lebih akurat yang dapat diterapkan pada skala industri.

2. Metodologi Penelitian

Tahapan penelitian dimulai dengan memuat dataset citra daun tebu yang kemudian melalui proses *preprocessing* berupa penyesuaian dimensi (*resizing*) untuk memenuhi spesifikasi *input* model CNN. Dataset tersebut dipartisi menjadi data pelatihan, validasi, dan pengujian guna menjamin objektivitas evaluasi performa. Selanjutnya, dilakukan eksperimen terkontrol menggunakan tiga arsitektur yaitu Xception, EfficientNetB0, dan ResNet50. Setiap model dilatih secara terpisah namun menggunakan konfigurasi hiperparameter yang identik untuk memastikan perbandingan yang adil. Kinerja setiap model dievaluasi secara

komprehensif menggunakan metrik *Accuracy*, *Loss*, *Precision*, *Recall*, dan *F1-score*. Tahap akhir melibatkan analisis komparatif hasil evaluasi untuk menentukan arsitektur yang paling efektif dalam mengklasifikasikan penyakit daun tebu.













Gambar 1. Diagram Alur Prosedur Riset.

2.1 Pengumpulan Dataset dan Akuisisi

Dataset riset ini menggunakan 2.521 gambar daun tebu yang terbagi ke dalam lima kelas, yaitu Healthy, Mosaic, Rust, Redrot, dan Yellow. Dataset ini diambil dari platform Kaggle dan memiliki variasi visual seperti perbedaan warna daun, pencahayaan, tingkat ketajaman citra, serta intensitas gejala penyakit, sehingga cocok digunakan untuk menguji kinerja berbagai arsitektur CNN dalam klasifikasi penyakit daun tebu.

Tabel 1. Contoh Dataset Daun Tebu dan Penyakit Daun Tebu

Healthy	Mosaic	Rust	Redrot	Yellow
				
				

Representasi visual untuk masing-masing kategori penyakit ditunjukkan pada Tabel 1. Daun dalam Kelas Healthy tidak menunjukkan gejala infeksi yang dikategorikan daun sehat.

Mosaic memiliki pola belang kekuningan, sedangkan Rust memiliki bercak kemerahan yang disebabkan oleh infeksi jamur. Redrot menunjukkan perubahan warna kemerahan memanjang pada tulang daun, dan kuning menunjukkan gejala klorosis. Perbedaan visual ini memberikan dasar yang kuat bagi model untuk melakukan penelitian tentang karakteristik penyakit.

Dataset memiliki total 2.521 citra, dibagi menjadi data pelatihan, validasi, dan pengujian sebagaimana ditunjukkan pada Tabel 2. Untuk memastikan bahwa model memiliki jumlah data yang cukup untuk belajar, validasi dan pengujian memberikan gambaran yang jelas tentang kemampuan model untuk diterapkan pada data yang tidak pernah dilihat sebelumnya.

Dataset yang digunakan dalam penelitian ini terdiri dari 2.521 citra daun tebu yang terbagi ke dalam lima kelas penyakit, yaitu Healthy, Mosaic, Rust, Redrot, dan Yellow. Untuk memastikan proses pelatihan dan evaluasi model dilakukan secara objektif, dataset dibagi menjadi tiga subset, yaitu data pelatihan (training), data validasi (validation), dan data pengujian (testing).

Pembagian dataset dilakukan dengan proporsi 80% data training, 10% data validasi, dan 10% data pengujian, sebagaimana ditunjukkan pada Tabel 2. Pembagian ini dilakukan secara proporsional berdasarkan kelas penyakit, sehingga setiap kelas tetap terwakili pada masing-masing subset data. Pendekatan ini bertujuan untuk meminimalkan bias kelas serta memastikan bahwa model CNN dapat dilatih dan dievaluasi secara adil pada seluruh kelas penyakit daun tebu.

Tabel 2. Pembagian Dataset.

Jenis Data	Jumlah Citra	Persentase
Training	2.048	80%
Validation	256	10%
Testing	217	10%
Total	2.521	100%

2.2 Preprocessing Data

Untuk memastikan bahwa seluruh gambar memenuhi standar input yang dibutuhkan oleh model CNN, tahap preprocessing dilakukan. Pada titik ini, citra dataset diubah setiap resolusinya menjadi 224×224 piksel bertujuan memenuhi kebutuhan arsitektur pre-trained Xception, EfficientNetB0, dan ResNet50. Ini memastikan proses ekstraksi fitur dapat dilakukan secara konsisten. Selain itu, nilai piksel dinormalisasi dalam rentang $[0-1]$ untuk menstabilkan distribusi data dan membantu mempercepat proses konvergensi selama pelatihan. Pada tahap preprocessing ini, gambar input menjadi lebih seragam dan terstruktur. Ini memungkinkan model untuk mempelajari pola visual penyakit daun tebu secara lebih efektif pada tahap pelatihan.

2.3 Arsitektur CNN dan Pembelajaran Transfer

Penelitian ini memanfaatkan tiga arsitektur CNN yang telah terlatih sebelumnya Xception, EfficientNetB0, dan ResNet50 dengan bobot awal yang berasal dari ImageNet sebagai fondasi representasi visual. Untuk menyesuaikan model dengan jumlah kelas penyakit daun tebu, lapisan klasifikasi bawaan setiap arsitektur dihilangkan dan diganti dengan rangkaian lapisan Global Average Pooling serta Dense berisi neuron sejumlah kelas target. Lapisan inti dari masing-masing arsitektur ini dibekukan untuk mempertahankan pemahaman umum tentang pola visual, sedangkan lapisan atas dibuka untuk latihan untuk menyesuaikan diri dengan fitur khusus dari gambar daun tebu. Metode pelatihan transfer dengan fine-tuning kecil ini memungkinkan proses pelatihan menjadi lebih efisien, terutama dalam kasus dataset yang tidak terlalu besar.

2.4 Pelatihan Model

Proses pelatihan model dilakukan menggunakan optimizer Adam dengan ukuran batch size sebesar 64. Seluruh model dilatih menggunakan jumlah epoch yang sama untuk menjaga kesetaraan kondisi eksperimen. Selama proses pelatihan, nilai akurasi dan loss pada data training dan data validasi dipantau untuk mengamati proses konvergensi dan stabilitas pembelajaran.

Dengan konfigurasi pelatihan yang identik pada seluruh arsitektur CNN, perbedaan performa yang dihasilkan dapat dianalisis secara objektif berdasarkan desain dan karakteristik masing-masing model.

2.5 Evaluasi Model

Pengujian Model dievaluasi dengan data pengujian untuk mengetahui seberapa umum model dapat diterapkan pada data yang baru. Lima matrik utama adalah akurasi, loss, ketepatan, dan recall, juga score F1. Skor akurasi, recall, dan F1-score sangat penting untuk klasifikasi multi-kelas karena mereka dapat menunjukkan ketepatan dan kelengkapan prediksi model dengan rumus 1,2,3 dan 4.

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

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

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

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

Accuracy menunjukkan tingkat ketepatan model dalam mengklasifikasikan seluruh citra uji dengan membandingkan jumlah prediksi yang benar bagi keseluruhan data. Metrik ini menggambarkan gambaran umum kinerja model, tetapi perlu dikombinasikan dengan matrik lain ketika data antar kelas tidak seimbang.

Precision mengukur ketepatan prediksi model pada suatu kelas, yaitu seberapa banyak prediksi positif yang benar dibandingkan kesemua hasil prediksi yang positif. Nilai yang tinggi pada presisi, itu menunjukkan rendahnya kekeliruan prediksi positif.

Recall mengukur kemampuan model dalam mendeteksi data positif, ini secara keseluruhan sebenarnya ada. Nilai kembali yang tinggi menandakan model mampu mendeteksi secara garisbesar citra penyakit daun tebu secara tepat.

F1-score merupakan rata-rata yang selaras antara ketepatan dan recall yang memberikan ukuran kinerja model secara seimbang, utamanya saat terjadi ketidakseimbangan jumlah data antar kelas.

Secara keseluruhan, metrik akurasi, ketepatan, recall, dan score F1 menampilkan evaluasi yang menyeluruh keperforma model CNN pada klasifikasi penyakit daun tebu. Keempat metrik ini menilai ketepatan prediksi, kemampuan deteksi kelas penyakit, serta keseimbangan hasil klasifikasi. Dengan demikian, evaluasi berbasis multi-metrik memastikan penilaian kinerja model yang lebih objektif dan andal.

3. Hasil dan Pembahasan

Bab ini menyajikan hasil dan pembahasan dari proses klasifikasi penyakit daun tebu menggunakan tiga arsitektur CNN, yaitu Xception, EfficientNetB0, dan ResNet50. Evaluasi dilakukan melalui tiga tahapan utama, yaitu pelatihan model menggunakan data training sebesar 80%, validasi model menggunakan data validasi sebesar 10%, serta pengujian model menggunakan data uji sebesar 10%, sesuai dengan pembagian dataset yang telah dijelaskan pada Bab III.

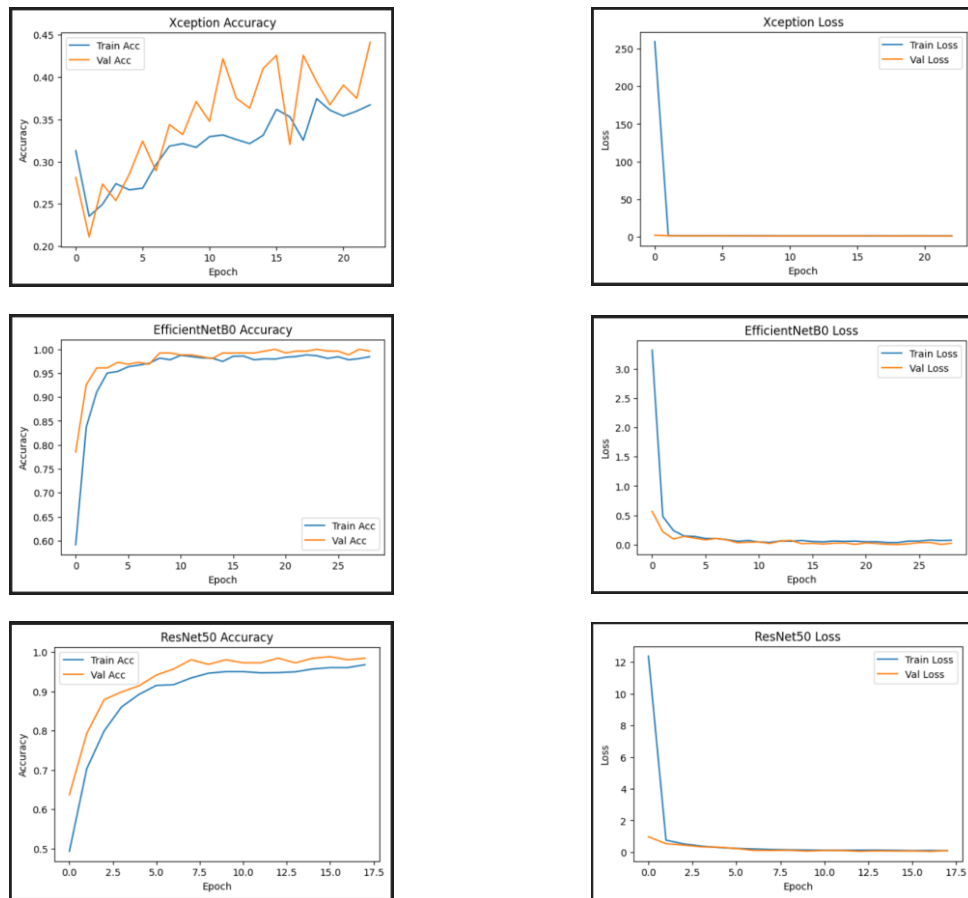
Evaluasi performa model dilakukan secara kuantitatif menggunakan metrik accuracy, loss, precision, recall, dan F1-score, serta secara kualitatif melalui visualisasi contoh hasil klasifikasi pada data validasi dan data uji.

3.1 Hasil Pelatihan Model Menggunakan Data Training (80%)

Proses pelatihan model dilakukan menggunakan 80% data training dari total dataset citra daun tebu. Ketiga model CNN dilatih menggunakan konfigurasi pelatihan yang sama untuk menjaga keadilan dalam perbandingan performa. Selama proses pelatihan, performa model dipantau menggunakan data validasi untuk mengamati tingkat konvergensi dan stabilitas pembelajaran. Parameter yang diamati pada tahap ini meliputi nilai accuracy dan loss pada data training dan data validasi di setiap epoch.

Kurva Akurasi Data Training dan Validasi
Xception, EfficientNetB0, ResNet50

Kurva Loss Data Training dan Validasi
Xception, EfficientNetB0, ResNet50



Gambar 2. Kurva 3 Model Akurasi dan Loss

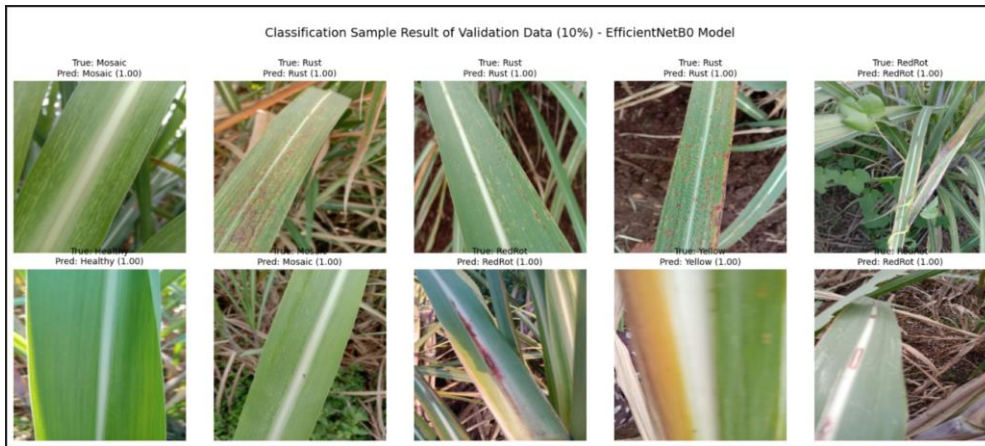
Berdasarkan kurva pelatihan pada gambar 2, EfficientNetB0 menunjukkan proses konvergensi paling cepat dan stabil dengan peningkatan akurasi yang signifikan serta penurunan loss yang konsisten. ResNet50 juga menunjukkan performa pelatihan yang stabil meskipun konvergensinya sedikit lebih lambat dibandingkan EfficientNetB0. Sebaliknya, Xception menunjukkan fluktuasi akurasi dan nilai loss yang relatif tinggi, yang mengindikasikan kesulitan dalam mempelajari pola visual penyakit daun tebu secara optimal.

3.2 Hasil Validasi Model Menggunakan Data Validasi (10%)


Tahap validasi dilakukan menggunakan 10% data validasi yang tidak digunakan dalam proses pelatihan. Validasi bertujuan untuk mengukur kemampuan generalisasi model selama proses training serta memastikan bahwa model tidak mengalami overfitting.

3.2.1 Hasil Klasifikasi Data Validasi


Hasil visualisasi pada gambar 3 dan gambar 4 membuktikan bahwa EfficientNetB0 dan ResNet50 dapat mengklasifikasikan seluruh sampel pada data validasi secara tepat dengan *confidence score* mencapai 1.00. Sebaliknya, pada gambar 5 dibuktikan bahwa Xception mengalami kendala dalam mengenali beberapa fitur tertentu, terutama prediksi citra penyakit sebagai kelas Healthy. Hal ini mengindikasikan bahwa Xception cenderung melewati pola nekrosis atau perubahan warna halus pada daun tebu, sehingga menganggap bahwa daun tersebut sebagai daun sehat.



Gambar 3. Hasil Klasifikasi Data Validasi (10%) Model EfficientNetB0



Gambar 4. Hasil Klasifikasi Data Validasi (10%) Model ResNet50



Gambar 5. Hasil Klasifikasi Data Validasi (10%) Model Xception

3.2.2 Evaluasi Performa Model pada Data Validasi

Tabel 3. Hasil Evaluasi Performa Model CNN pada Data Validasi (10%)

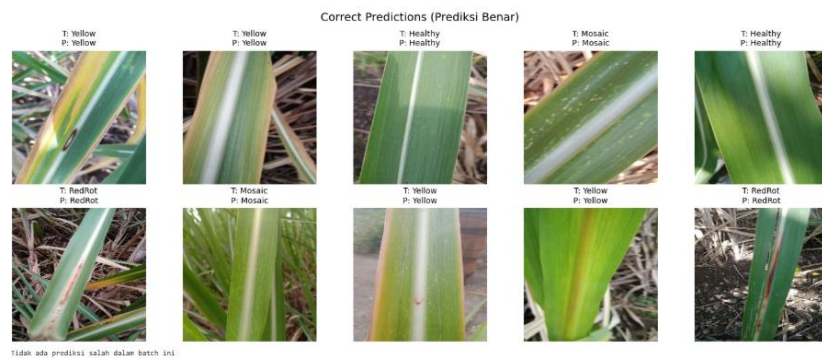
Model	Akurasi	Precision	Recall	F1-score
Xception	0.484	0.963	0.304	0.460
EfficientNetB0	0.996	0.996	0.996	0.996
ResNet50	0.968	0.976	0.968	0.972

Berdasarkan Tabel 3, EfficientNetB0 menunjukkan performa validasi terbaik dengan nilai metrik yang tinggi dan seimbang. ResNet50 juga menunjukkan performa yang sangat baik dengan selisih kecil dibandingkan EfficientNetB0. Model Xception menunjukkan ketidakseimbangan antara precision dan recall, yang mengindikasikan keterbatasan dalam mendeteksi seluruh kelas penyakit daun tebu.

3.3 Hasil Pengujian Model Menggunakan Data Uji (10%)

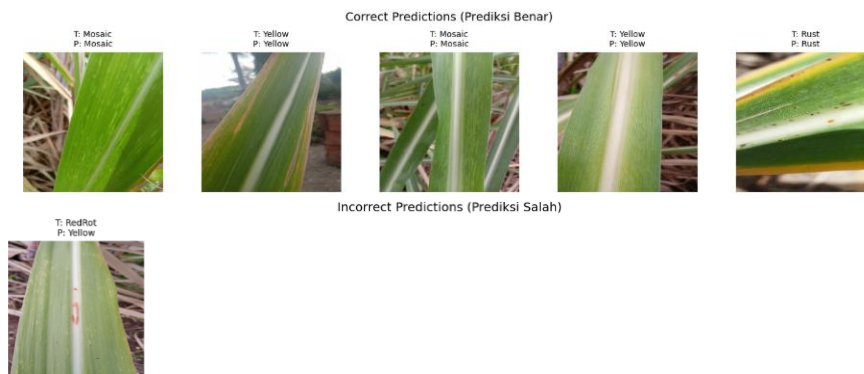
Tahap pengujian dilakukan menggunakan 10% data uji yang sepenuhnya terpisah dari data training dan data validasi. Tahap ini digunakan untuk mengevaluasi performa akhir model terhadap data yang benar-benar baru.

3.3.1 Hasil Klasifikasi Data Pengujian



Tidak ada prediksi salah dalam batch ini

Gambar 6. Hasil Klasifikasi Data Pengujian (10%) Model EfficientNetB0



Gambar 7. Hasil Klasifikasi Data Pengujian (10%) Model ResNet50



Gambar 8. Hasil Klasifikasi Data Pengujian (10%) Model Xception

Hasil pengujian pada gambar 6 dan 7 menunjukkan bahwa EfficientNetB0 dan ResNet50 mampu mengklasifikasikan citra penyakit daun tebu secara konsisten dan akurat dengan ResNet50 hanya memiliki 1 kesalahan. Model Xception yang ditunjukkan di gambar 8 masih memperlihatkan banyak kesalahan klasifikasi pada beberapa kelas penyakit.

3.3.2 Evaluasi Performa Model pada Data Pengujian

Hasil pengujian menunjukkan bahwa EfficientNetB0 memperoleh performa terbaik dengan nilai metrik sempurna pada seluruh parameter evaluasi. ResNet50 menunjukkan performa yang sangat stabil dan mendekati EfficientNetB0. Model Xception memiliki performa terendah dengan nilai accuracy dan F1-score yang rendah.

Tabel 4. Hasil Evaluasi Performa Model CNN pada Data Pengujian






Model	Akurasi	Loss	Precision	Recall	F1-score
Xception	0.419	1.183	0.889	0.258	0.400
EfficientNetB0	1,000	0,002	1,000	1,000	1,000
ResNet50	0.986	0.069	0.986	0.986	0.986

3.4 Analisis Precision, Recall, dan F1-score

Analisis lanjutan dilakukan dengan membandingkan kurva precision, recall, dan F1-score pada data training dan validasi.

Kurva Precision Xception, EfficientNetB0, ResNet50

Kurva Recall Xception, EfficientNetB0, ResNet50




Gambar 9. Kurva 3 Model Precision dan Recall

Dalam grafik *precision* dan *recall* yang dtunjukkan di gambar 9, EfficientNetB0 menunjukkan nilai yang paling stabil dan tinggi, menunjukkan kemampuan prediksi yang akurat dan kemampuan mendeteksi hampir seluruh sampel pada data validasi. Sama halnya ResNet50, menunjukkan kinerja yang bagus dengan nilai ketepatan dan recall yang seimbang, meskipun ada sedikit perbedaan. Sebaliknya, Xception menunjukkan precision yang relatif

tinggi tetapi recall yang rendah; ini menunjukkan bahwa model tidak dapat menemukan sebagian besar sampel penyakit daun tebu.

Bagian ini menampilkan grafik F1-score untuk ketiga model CNN. Grafik ini digunakan untuk menilai keseimbangan antara precision dan recall dalam proses klasifikasi. Perbandingan F1-score memberikan gambaran menyeluruh terhadap efektivitas masing-masing model dalam mengklasifikasikan penyakit daun tebu.

Xception, EfficientNetB0, ResNet50



Gambar 10. Kurva 3 Model F1-score

Dalam grafik nilai F1-score yang ditunjukkan gambar 10, EfficientNetB0 menunjukkan nilai yang sangat tinggi dan stabil sepanjang proses pelatihan, menunjukkan keserasian yang cocok antara ketepatan dan recall. ResNet50 juga menunjukkan pada nilai F1-score yang tinggi dengan fluktuasi kecil, menunjukkan performa klasifikasi yang konsisten. Sedangkan, Xception memiliki nilai F1-score yang rendah dan tidak stabil, menunjukkan ketidakseimbangan antara precision dan recall, sehingga kinerjanya kurang optimal. Sebaliknya, Xception menunjukkan nilai recall yang rendah meskipun precision tinggi, yang menyebabkan nilai F1-score rendah.

3.5 Pembahasan Komparatif

Berdasarkan hasil validasi dan pengujian, EfficientNetB0 merupakan arsitektur CNN yang paling optimal dalam mengklasifikasikan penyakit daun tebu. Pendekatan compound scaling memungkinkan EfficientNetB0 mempelajari fitur visual secara efisien dan stabil. Hasil penelitian ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa arsitektur EfficientNet memiliki keunggulan dalam stabilitas pelatihan dan efisiensi skala, di mana EfficientNetV2L dilaporkan mampu mencapai rata-rata akurasi pelatihan sebesar 98% selama 5 epoch [14].

ResNet50 menunjukkan performa yang sangat baik dan konsisten berkat mekanisme residual learning yang membantu mempertahankan informasi fitur penting. Sebaliknya, Xception menunjukkan performa paling rendah akibat ketidakseimbangan prediksi dan ketidakstabilan selama proses pelatihan. Hasil ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa arsitektur CNN dengan stabilitas pelatihan dan efisiensi skala yang baik cenderung menghasilkan performa klasifikasi yang lebih unggul Suprihanto dkk [15].

3.6 Pembahasan

Hasil evaluasi kinerja berdasarkan tabel pengujian menunjukkan bahwa ketiga arsitektur CNN yang digunakan berbeda dalam kinerja. Dengan akurasi sebesar 100% dan nilai

loss paling rendah, EfficientNetB0 mencapai hasil terbaik pada semua matrik evaluasi. Ini menunjukkan kemampuan model untuk mempelajari pola penyakit daun tebu secara efektif dan stabil. Nilai akurasi, recall, juga F1-score yang tinggi membuktikan bahwa EfficientNetB0 tidak hanya akurat dalam melakukan prediksi, tetapi juga dapat secara konsisten menemukan hampir seluruh sampel penyakit. Selain itu, ResNet50 menunjukkan kinerja yang luar biasa dengan akurasi 98,2% dan keseimbangan antara akurasi dan recall, menunjukkan bahwa mekanisme pelatihan residual mampu menyimpan informasi penting selama proses pelatihan. Sebaliknya, Xception menunjukkan hasil yang paling buruk dengan akurasi 40,6% dan nilai loss yang sangat tinggi, menunjukkan bahwa model mungkin mengalami kesulitan untuk menyesuaikan dengan karakteristik dataset. sebab penerapan klasifikasi penyakit daun pada model xception sangat dipengaruhi oleh kualitas data dan distribusi kelas, terutama pada citra daun dengan variasi tekstur dan warna yang kompleks [16].

Hasil tabel evaluasi diperkuat dengan analisis grafik akurasi dan loss selama pelatihan. Pola konvergensi EfficientNetB0 yang cepat dan stabil menunjukkan peningkatan akurasi secara konsisten seiring bertambahnya epoch, sementara nilai loss turun secara signifikan tanpa perubahan yang signifikan. Hal ini menunjukkan bahwa proses pembelajaran berjalan secara stabil dengan kecenderungan konvergensi yang baik. Meskipun ada sedikit variasi pada tahap awal pelatihan, ResNet50 tetap menunjukkan pelatihan yang stabil. Ini masih dapat ditoleransi dalam jaringan berlapis dalam. Berbeda dengan kedua model tersebut, Xception menunjukkan nilai loss yang tidak stabil dan fluktuasi akurasi yang tajam, ini menunjukkan ketidaksesuaian arsitektural dalam distribusi data dan variasi visual pada gambar daun tebu.

Selain itu, grafik precision, recall, dan skor F1-score memberikan informasi lebih lanjut tentang karakteristik prediksi masing-masing model. EfficientNetB0 mempertahankan nilai precision dan recall yang tinggi dan seimbang, dan menghasilkan F1-score yang hampir sempurna, menunjukkan kemampuan klasifikasi yang andal pada seluruh kelas penyakit. ResNet50 juga menghasilkan F1-score yang tinggi dengan sedikit fluktuasi, menunjukkan performa yang konsisten meskipun tidak seoptimal dengan EfficientNetB0. Sedangkan, Xception menunjukkan ketidakseimbangan yang jelas antara precision dan recall; precision relatif tinggi tetapi recall rendah, yang mengakibatkan skor F1 yang rendah. Pola ini menunjukkan bahwa Xception tidak cocok untuk klasifikasi penyakit daun tebu karena cenderung gagal mendeteksi sebagian besar sampel positif. Secara keseluruhan, temuan penelitian ini menunjukkan bahwa, dibandingkan dengan model CNN lainnya [17 - 18], arsitektur CNN dengan efisiensi skala dan stabilitas pelatihan yang baik, seperti EfficientNetB0, menangani kompleksitas visual gambar penyakit daun tebu dengan lebih baik.

3.7 Implikasi Temuan Penelitian terhadap Penelitian Terdahulu

Temuan dalam penelitian ini memberikan kontribusi empiris terhadap kajian klasifikasi penyakit daun tanaman berbasis *Convolutional Neural Network* (CNN), khususnya pada komoditas tebu yang masih relatif terbatas diteliti. Hasil penelitian menunjukkan bahwa EfficientNetB0 secara konsisten menghasilkan performa terbaik dibandingkan Xception dan ResNet50 pada kondisi pelatihan yang identik, baik pada tahap validasi maupun pengujian.

Hasil ini memperkuat temuan Mardiana dan Windari yang melaporkan keunggulan EfficientNet dalam klasifikasi penyakit daun tanaman dengan variasi tekstur dan warna yang kompleks [4]. Temuan ini juga sejalan dengan konsep *compound scaling* yang dikemukakan oleh Tan et al., yang menyatakan bahwa EfficientNet mampu mencapai keseimbangan optimal antara efisiensi parameter dan kemampuan representasi fitur visual [10]. Dengan demikian, penelitian ini memperluas validitas pendekatan tersebut ke konteks penyakit daun tebu.

Performa stabil ResNet50 dalam penelitian ini juga menguatkan hasil Suprianto et al., yang menunjukkan bahwa arsitektur berbasis residual memiliki kemampuan generalisasi yang baik pada klasifikasi penyakit daun tanaman [12]. Mekanisme skip connection pada ResNet50 terbukti membantu mempertahankan fitur penting selama pelatihan, meskipun performanya masih berada di bawah EfficientNetB0.

Sebaliknya, rendahnya performa Xception dalam penelitian ini berbeda dengan temuan Aryadi dan Suhendar yang melaporkan kinerja Xception yang baik pada klasifikasi citra tanaman lain [8]. Perbedaan ini menunjukkan bahwa efektivitas arsitektur CNN sangat dipengaruhi oleh karakteristik dataset. Hasil penelitian ini sejalan dengan Pamungkas dan Amrulloh, yang menunjukkan bahwa Xception cenderung mengalami ketidakseimbangan antara precision dan recall pada citra daun dengan variasi tekstur dan warna yang kompleks [17].

Secara keseluruhan, penelitian ini mengintegrasikan dan mempertegas temuan-temuan terdahulu dengan menunjukkan bahwa arsitektur CNN yang memiliki efisiensi skala dan stabilitas pelatihan yang tinggi, seperti EfficientNetB0, lebih sesuai untuk klasifikasi penyakit daun tebu. Temuan ini memberikan kontribusi konseptual dalam pemilihan arsitektur CNN yang tepat untuk pengembangan sistem deteksi penyakit tanaman berbasis kecerdasan buatan.

4. Kesimpulan dan Saran

Penelitian ini telah berhasil melakukan analisis komparatif terhadap tiga arsitektur *Convolutional Neural Network* (CNN), yaitu Xception, EfficientNetB0, dan ResNet50, dalam klasifikasi penyakit daun tebu berbasis pendekatan transfer learning. Eksperimen dilakukan menggunakan dataset berjumlah 2.521 citra daun tebu yang terbagi ke dalam lima kelas penyakit, dengan pembagian data sebesar 80% untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian.

Berdasarkan hasil evaluasi pada data validasi dan data pengujian menggunakan metrik accuracy, loss, precision, recall, dan F1-score, diperoleh kesimpulan bahwa EfficientNetB0 merupakan arsitektur CNN dengan performa terbaik. Model ini mencapai akurasi tertinggi hingga 100% pada data pengujian, disertai nilai precision, recall, dan F1-score yang tinggi dan seimbang, yang menunjukkan kemampuan generalisasi dan stabilitas pelatihan yang sangat baik dalam mengklasifikasikan penyakit daun tebu.

Arsitektur ResNet50 juga menunjukkan performa yang sangat baik dan stabil dengan akurasi sebesar 98,2%, yang menegaskan efektivitas mekanisme residual learning dalam mempertahankan fitur penting selama proses pelatihan. Sebaliknya, Xception menunjukkan performa terendah dengan akurasi sebesar 40,6%, yang ditandai dengan ketidakseimbangan antara precision dan recall. Hal ini mengindikasikan bahwa arsitektur Xception kurang optimal dalam menangani kompleksitas visual dan variasi tekstur pada citra penyakit daun tebu.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa arsitektur CNN yang mengoptimalkan efisiensi skala jaringan dan stabilitas pelatihan, seperti EfficientNetB0, lebih sesuai untuk klasifikasi penyakit daun tebu dibandingkan arsitektur CNN lainnya. Temuan ini memberikan kontribusi empiris dalam pemilihan arsitektur CNN yang tepat untuk pengembangan sistem deteksi penyakit tanaman berbasis kecerdasan buatan.

Daftar Referensi

- [1] T. Yulianti, "Status Dan Strategi Teknologi Pengendalian Penyakit Utama Tebu Di Indonesia Status and Control Strategy of Important Sugarcane Diseases In ...," *Perspektif*, vol. 19, no. 1, pp. 1–16, 2020, [Online]. Available: <http://ejurnal.litbang.pertanian.go.id/index.php/psp/article/view/11057>
- [2] Della Adelia, Zahratul Fitri, and Cut Agusniar, "Deteksi Daun Herbal Dan Beracun Menggunakan Convolutional Neural Network Untuk Klasifikasi Tanaman Herbal Dan Beracun," *Rabit J. Teknol. dan Sist. Inf. Univrab*, vol. 10, no. 2, pp. 204–216, 2025, doi: 10.36341/rabit.v10i2.6025.
- [3] M. Hasan, B. Tanawala, and K. J. Patel, "Deep Learning Precision Farming: Tomato Leaf Disease Detection by Transfer Learning," *SSRN Electron. J.*, pp. 1–5, 2019, doi: 10.2139/ssrn.3349597.
- [4] W. O. Mardiana, N. A., & Windari, "G-Tech : Jurnal Teknologi Terapan," *G-Tech J. Teknol. Terap.*, vol. 8, no. 1, pp. 186–195, 2024.
- [5] I. Topan Adib Amrulloh, B. Nurina Sari, and T. Nur Padilah, "Evaluasi Augmentasi Data Pada Deteksi Penyakit Daun Tebu Dengan Yolov8," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 4, pp. 7547–7552, 2024, doi: 10.36040/jati.v8i4.10267.
- [6] S. Firmansyah, E. Yulia Puspaningrum, and E. Prakarsa Mandyartha, "Implementasi Transfer Learning Dengan Perbandingan Nilai Learning Rate Pada Klasifikasi Citra Penyakit Daun Tebu Berbasis Web," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 5, pp. 7357–7364, 2025, doi: 10.36040/jati.v9i5.14609.
- [7] S. Agustiani, R. Aryanti, S. Khotimatul Wildah, Y. T. Arifin, S. Marlina, and T. Misriati, "Optimisasi Model Deep Learning untuk Deteksi Penyakit Daun Tebu dengan Fine-Tuning MobileNetV2," *J. Informatics Manag. Inf. Technol.*, vol. 4, no. 4, pp. 150–157, 2024.
- [8] W. L. Pratitis, K. Kurniasari, and H. Al Fata, "Classification of Spotted Disease on Sugarcane Leaf Image Using Convolutional Neural Network Algorithm," *JTECS J. Sist.*

- Telekomun. Elektron. Sist. Kontrol Power Sist. dan Komput.*, vol. 3, no. 2, p. 117, 2023, doi: 10.32503/jtecs.v3i2.3433.
- [9] A. K. Bagchi, M. A. Haider Chowdhury, and S. A. Fattah, "Sugarcane Disease Classification using Advanced Deep Learning Algorithms: A Comparative Study," *Proc. - 6th Int. Conf. Electr. Eng. Inf. Commun. Technol. ICEEICT 2024*, pp. 887–892, 2024, doi: 10.1109/ICEEICT62016.2024.10534394.
- [10] I. Aryadi and A. Suhendar, "Implementasi Arsitektur Xception Dalam Menentukan Kematangan Tandan Buah Segar Kelapa Sawit," *Jutisi J. Ilm. Tek. Inform. dan Sist. Inf.*, vol. 13, no. 3, 2024, doi: 10.35889/jutisi.v13i3.2337.
- [11] J. R. Ziliwu, G. C. Setyawan, and H. Budiati, "Penerapan ESP32-CAM dan TinyML dalam Klasifikasi Gambar Buah dan Sayuran," *Jutisi J. Ilm. Tek. Inform. dan Sist. Inf.*, vol. 13, no. 1, p. 584, 2024, doi: 10.35889/jutisi.v13i1.1869.
- [12] M. Kevin Santosa, M. Hanindia Prami Swari, and A. Nugroho Sihananto, "Implementasi Arsitektur Alexnet Dan Resnet34 Pada Klasifikasi Citra Penyakit Daun Kentang Menggunakan Transfer Learning," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 5, pp. 3293–3301, 2024, doi: 10.36040/jati.v7i5.7337.
- [13] M. I. Hossen, M. Awrangjeb, S. Pan, and A. Al Mamun, "Transfer learning in agriculture: a review," *Artif. Intell. Rev.*, vol. 58, no. 4, 2025, doi: 10.1007/s10462-024-11081-x.
- [14] A. Noercholis and S. Y. Riska, "Comparative Study of NASNetLarge and EfficientNetV2L Architectures for Brain Tumor Classification Using CNN Methods," in *2025 9th International Conference On Electrical, Electronics And Information Engineering (ICEEIE)*, 2025, pp. 1–6. doi: 10.1109/ICEEIE66203.2025.11253976.
- [15] S. Suprihanto, I. Awaludin, M. Fadhil, and M. A. Z. Zulfikor, "Analisis Kinerja ResNet-50 dalam Klasifikasi Penyakit pada Daun Kopi Robusta," *J. Inform.*, vol. 9, no. 2, pp. 116–122, 2022, doi: 10.31294/inf.v9i1.13049.
- [16] D. P. Pamungkas and M. F. Amrulloh, "Analisis Hasil Klasifikasi Penyakit Daun Bawang Merah Menggunakan Cnn Arsitektur Exception," *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 10, no. 1, pp. 359–366, 2025, doi: 10.29100/jupi.v10i1.5875.
- [17] K.I.I Saputra, M.R. Muttaqin, & T.I Hermanto, "Klasifikasi Citra Mutu Kemasan Menggunakan Metode Convolutional Neural Network Dengan Arsitektur MobileNetV2." *Progresif: Jurnal Ilmiah Komputer*, vol. 19, no. 3, pp. 613-622, 2023.
- [18] M.I. Rasyid, & L.M. Wisudawati, "Klasifikasi hama ulat pada citra daun sawi berbasis convolutional neural network dengan model Xception." *Jutisi: Jurnal Ilmiah Teknik Informatika Dan Sistem Informasi*, vol. 13, no. 2, pp. 870-880, 2024.