

Analisis Performa InceptionV3 Berbasis Transfer Learning untuk Klasifikasi Penyakit Daun Tebu

^{1*}Muhammad Fernanda Mulya Putra, ²Danang Wahyu Widodo, ³Patmi Kasih

¹²³ Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹muhammadfernanda2711@gmail.com, ²danangwahyuwidodo@unpkediri.ac.id,
³patmikasih@unpkediri.ac.id

Penulis Korespondens : Muhammad Fernanda Mulya Putra

Abstrak—Penyakit daun tebu dapat menurunkan produktivitas tanaman dan memerlukan identifikasi yang cepat serta akurat untuk mendukung pengelolaan tanaman yang efektif. Penelitian ini bertujuan menganalisis performa InceptionV3 berbasis *transfer learning* dalam mengklasifikasikan penyakit daun tebu menggunakan citra digital. Dataset yang digunakan terdiri atas 1.999 citra daun tebu yang dikelompokkan ke dalam empat kelas, yaitu *Mosaic*, *RedRot*, *Rust*, dan *Yellow*. Dataset dibagi menjadi data latih, validasi, dan uji dengan rasio 70:15:15. Proses pelatihan dilakukan melalui dua fase, yaitu *feature extraction* dan *fine-tuning*, serta didukung penerapan augmentasi data untuk meningkatkan kemampuan generalisasi model. Hasil pengujian menunjukkan bahwa model mampu menghasilkan akurasi sebesar 86,18 persen dengan nilai *precision*, *recall*, dan *F1-score* yang seimbang. Temuan ini menunjukkan bahwa InceptionV3 berbasis *transfer learning* efektif digunakan untuk klasifikasi penyakit daun tebu dan berpotensi mendukung pengembangan sistem identifikasi penyakit tanaman berbasis kecerdasan buatan.

Kata Kunci—citra digital, InceptionV3, klasifikasi penyakit, tebu, *transfer learning*

Abstract—Sugarcane leaf diseases can reduce crop productivity and require rapid and accurate identification to support effective crop management. This study aims to analyze the performance of InceptionV3 based on transfer learning for classifying sugarcane leaf diseases using digital images. The dataset consisted of 1,999 sugarcane leaf images categorized into four classes: *Mosaic*, *RedRot*, *Rust*, and *Yellow*. The dataset was divided into training, validation, and testing sets with a ratio of 70:15:15. The training process was conducted through feature extraction and fine-tuning phases, supported by data augmentation to improve model generalization. The evaluation results showed that the model achieved an accuracy of 86.18 percent with balanced precision, recall, and F1-score values. These findings indicate that InceptionV3 based on transfer learning is effective for sugarcane leaf disease classification and has the potential to support the development of artificial intelligence based plant disease identification systems.

Keywords—disease classification, digital image, InceptionV3, sugarcane, transfer learning

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Tebu (*Saccharum officinarum* L.) merupakan salah satu komoditas perkebunan strategis yang berperan penting sebagai bahan baku industri gula dan pendukung ketahanan pangan. Produktivitas tanaman tebu sangat dipengaruhi oleh kondisi kesehatan tanaman, khususnya serangan penyakit daun seperti *Mosaic*, *RedRot*, *Rust*, dan *Yellow* yang dapat menurunkan

kualitas maupun kuantitas hasil panen apabila tidak terdeteksi secara dini [1]. Oleh karena itu, identifikasi penyakit secara cepat dan akurat menjadi faktor penting dalam mendukung pengelolaan tanaman tebu yang berkelanjutan.

Identifikasi penyakit daun tebu umumnya masih dilakukan melalui pengamatan visual oleh petani maupun tenaga ahli. Metode ini membutuhkan pengalaman yang memadai, memerlukan waktu relatif lama, serta rentan terhadap kesalahan diagnosis akibat kemiripan gejala antarpenyakit. Selain itu, keterbatasan jumlah tenaga ahli menyebabkan proses identifikasi menjadi kurang efektif, terutama pada area perkebunan yang luas [2]. Kondisi tersebut mendorong perlunya pengembangan sistem identifikasi penyakit yang lebih cepat, objektif, dan konsisten.

Perkembangan *Artificial Intelligence* dan *Computer Vision* telah mendorong pemanfaatan *Deep Learning* dalam klasifikasi penyakit tanaman berbasis citra digital. Salah satu pendekatan yang banyak digunakan adalah *Convolutional Neural Network* (CNN) yang mampu mengekstraksi fitur visual secara otomatis dan menghasilkan performa klasifikasi yang lebih baik dibandingkan metode konvensional [3]. Selain itu, teknik *transfer learning* memungkinkan pemanfaatan model yang telah dilatih pada dataset berskala besar sehingga mampu meningkatkan efisiensi pelatihan dan performa klasifikasi pada dataset yang lebih terbatas [4].

Berbagai penelitian menunjukkan bahwa *Deep Learning* berbasis CNN mampu meningkatkan akurasi klasifikasi penyakit tanaman dibandingkan pendekatan konvensional berbasis *ekstraksi fitur* manual. Mazumder dkk. [5] menunjukkan bahwa pendekatan *transfer learning* tetap mampu menghasilkan performa yang tinggi meskipun menggunakan jumlah citra yang relatif terbatas. Pada klasifikasi penyakit daun tebu, Hu dkk. [6], Srinivasan dkk. [7], Maurya dkk. [8] menunjukkan bahwa pendekatan *weighted ensemble*, *Deep Neural Network*, dan *multiscale attention* mampu meningkatkan kemampuan model dalam mengenali berbagai kelas penyakit serta membedakan gejala yang memiliki karakteristik visual serupa. Temuan tersebut menunjukkan bahwa peningkatan performa klasifikasi umumnya dicapai melalui pengembangan arsitektur yang semakin kompleks.


Meskipun demikian, sebagian besar penelitian terdahulu berfokus pada modifikasi arsitektur, pendekatan *ensemble*, maupun mekanisme *attention* yang meningkatkan kompleksitas model. Di sisi lain, kajian mengenai penerapan InceptionV3 pada klasifikasi penyakit daun tebu, khususnya yang mengevaluasi performa model menggunakan berbagai metrik pada setiap kelas penyakit, masih relatif terbatas. InceptionV3 merupakan arsitektur CNN yang dirancang untuk melakukan *ekstraksi fitur* multiskala secara efisien melalui modul *Inception* sehingga mampu menghasilkan performa klasifikasi yang kompetitif dengan efisiensi komputasi yang baik [9]. Oleh karena itu, diperlukan kajian lebih lanjut untuk mengkaji kemampuan InceptionV3 dalam mengidentifikasi berbagai penyakit daun tebu melalui pendekatan *transfer learning*.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menganalisis performa InceptionV3 berbasis *transfer learning* dalam mengklasifikasikan penyakit daun tebu menggunakan citra digital. Evaluasi dilakukan terhadap empat kelas penyakit, yaitu *Mosaic*, *RedRot*, *Rust*, dan *Yellow*, menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan

confusion matrix guna memperoleh gambaran yang komprehensif mengenai kemampuan model dalam mengenali setiap kelas penyakit.

II. METODE


Penelitian ini menggunakan pendekatan *deep learning* berbasis InceptionV3 dan *transfer learning* untuk mengklasifikasikan penyakit daun tebu. Tahapan penelitian meliputi pembagian dataset, *preprocessing* dan augmentasi data, pelatihan model, serta evaluasi kinerja. Alur penelitian ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

A. Dataset dan Pembagian Data

Dataset yang digunakan dalam penelitian ini bersumber dari *Mendeley Data* dan terdiri atas 1.999 citra daun tebu yang dikelompokkan ke dalam empat kelas penyakit, yaitu *Mosaic*, *RedRot*, *Rust*, dan *Yellow*. Contoh citra dari masing-masing kelas ditunjukkan pada Gambar 2



Gambar 2. Dataset

Setiap kelas memiliki jumlah citra yang relatif seimbang sehingga dapat mengurangi potensi bias model selama proses pelatihan. Distribusi dataset ditunjukkan pada Tabel 1.

Tabel 1. Distribusi Dataset per Kelas

Kelas	Jumlah Citra	Persentase
<i>Mosaic</i>	462	23,11%
<i>RedRot</i>	518	25,91%
<i>Rust</i>	514	25,71%

<i>Yellow</i>	505	25,26%
Total	1.999	100%

Dataset dibagi menjadi data latih, data validasi, dan data uji dengan rasio 70:15:15 secara proporsional pada setiap kelas menggunakan *random seed* 42 untuk memastikan reproduktibilitas eksperimen. Distribusi pembagian dataset ditunjukkan pada Tabel 2.

Tabel 2. Pembagian Dataset

Dataset	Jumlah Citra
<i>Train</i>	1.397
<i>Validation</i>	298
<i>Test</i>	304
Total	1.999

B. Preprocessing dan Augmentasi Data

Seluruh citra diubah ukurannya menjadi 299×299 piksel sesuai ukuran masukan yang digunakan oleh arsitektur InceptionV3. Selanjutnya dilakukan normalisasi nilai piksel menggunakan Persamaan (1).

$$x' = \frac{x}{255} \quad (1)$$

dengan (x) menyatakan nilai piksel asli dan (x') menyatakan nilai piksel setelah normalisasi pada rentang 0–1.


Untuk meningkatkan keragaman representasi fitur dan mengurangi risiko overfitting, diterapkan teknik augmentasi data pada data latih menggunakan beberapa transformasi citra. Augmentasi data diketahui mampu meningkatkan kemampuan generalisasi model dengan menghasilkan variasi sampel pelatihan yang lebih beragam tanpa menambah data baru secara manual [10]. Augmentasi hanya diterapkan pada data latih, sedangkan data validasi dan data uji hanya melalui proses normalisasi. Parameter augmentasi yang digunakan ditunjukkan pada Tabel 3.

Tabel 3. Parameter *Augmentasi* Data

Parameter	Nilai
<i>Rotasi</i>	±30°
<i>Pergeseran horizontal & vertikal</i>	20%
<i>Shear</i>	20%
<i>Zoom</i>	20%
<i>Flip horizontal & vertikal</i>	Aktif
Variasi kecerahan	0,8 – 1,2

C. Arsitektur Model

InceptionV3 merupakan arsitektur *Convolutional Neural Network* (CNN) yang mampu mengekstraksi fitur citra pada berbagai skala melalui modul *Inception*. Pada penelitian ini, InceptionV3 digunakan sebagai model yang telah dilatih sebelumnya menggunakan dataset *ImageNet*, kemudian lapisan klasifikasi bawaannya diganti untuk mengklasifikasikan empat kelas penyakit daun tebu. Arsitektur model yang digunakan ditunjukkan pada Gambar 2.



Gambar 3. Arsitektur model InceptionV3 berbasis *transfer learning*

Berdasarkan Gambar 3, citra masukan berukuran 299×299 piksel diproses oleh InceptionV3 untuk mengekstraksi karakteristik visual daun tebu. Fitur yang dihasilkan kemudian diringkas melalui *Global Average Pooling* dan dinormalisasi menggunakan *Batch Normalization* sebelum diproses oleh dua lapisan *Dense* berukuran 512 dan 256 neuron dengan aktivasi *ReLU*. Untuk mengurangi risiko *overfitting*, diterapkan dua lapisan *Dropout* dengan nilai 0,5 dan 0,3. Pada lapisan keluaran digunakan fungsi aktivasi *Softmax* dengan empat neuron yang merepresentasikan kelas *Mosaic*, *RedRot*, *Rust*, dan *Yellow*. Konfigurasi lengkap model disajikan pada Tabel 4.

Tabel 4. Konfigurasi *Custom Classification Head*

Layer	Konfigurasi
<i>Global Average Pooling 2D</i>	—
<i>Batch Normalization</i>	—
<i>Dense</i>	512 neuron, aktivasi <i>ReLU</i>
<i>Dropout</i>	Rate = 0,5
<i>Dense</i>	256 neuron, aktivasi <i>ReLU</i>
<i>Dropout</i>	Rate = 0,3
<i>Dense (Output)</i>	4 neuron, aktivasi <i>Softmax</i>

D. Prosedur Pelatihan

Pelatihan model dilakukan dalam dua fase, yaitu *feature extraction* dan *fine-tuning*. Pada fase *feature extraction*, seluruh layer InceptionV3 dibekukan (*frozen*) sehingga hanya *custom classification head* yang dilatih. Setelah model mencapai performa yang stabil, proses dilanjutkan ke fase *fine-tuning* dengan membuka sebagian layer atas InceptionV3 mulai dari layer ke-249 untuk menyesuaikan model terhadap karakteristik citra penyakit daun tebu. Pendekatan *fine-tuning* memungkinkan model beradaptasi terhadap domain target dengan tetap memanfaatkan pengetahuan yang telah dipelajari dari dataset sumber melalui *transfer learning* [11]. Konfigurasi pelatihan pada kedua fase ditunjukkan pada Tabel 5.

Tabel 5. Konfigurasi Pelatihan Model

Parameter	Fase 1 (<i>Feature Extraction</i>)	Fase 2 (<i>Fine-Tuning</i>)
Layer dibekukan	Seluruh layer InceptionV3	Layer 1–248
Layer dilatih	<i>Classification head</i>	62 layer atas + <i>classification head</i>
<i>Learning rate</i>	1×10^{-4}	1×10^{-5}
Maks. epoch	50	30

Optimizer	Adam	Adam
Loss function	Categorical Cross-Entropy	Categorical Cross-Entropy
Early stopping patience	10	10

Fungsi loss yang digunakan adalah *categorical cross-entropy* sebagaimana ditunjukkan pada Persamaan (2).

$$L = - \sum_{i=1}^n y_i \log(\hat{y}_i) \quad (2)$$

dengan y_i menyatakan label aktual kelas ke-(i), sedangkan $\hat{y}_i$ menyatakan probabilitas prediksi model untuk kelas ke-(i).

E. Evaluasi Model

Performa model dievaluasi menggunakan empat metrik klasifikasi, yaitu *accuracy*, *precision*, *recall*, dan *F1-score* [12]. Rumus masing-masing metrik ditunjukkan pada Persamaan (3)–(6).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

$$Precision = \frac{TP}{TP+FP} \quad (4)$$

$$Recall = \frac{TP}{TP+FN} \quad (5)$$


$$F1\ Score = \frac{2 \times (Precision \times Recall)}{Precision + Recall} \quad (6)$$

dengan (TP) (*True Positive*), (TN) (*True Negative*), (FP) (*False Positive*), dan (FN) (*False Negative*) merupakan komponen penyusun *confusion matrix*. Selain itu, *confusion matrix* digunakan untuk menganalisis pola kesalahan klasifikasi pada setiap kelas penyakit.

III. HASIL DAN PEMBAHASAN

A. Hasil Pelatihan Model

Proses pelatihan model InceptionV3 dilakukan melalui dua fase, yaitu *feature extraction* dan *fine-tuning*. Pada fase *feature extraction*, seluruh layer InceptionV3 dibekukan sehingga proses pembelajaran hanya dilakukan pada *classification head*. Pelatihan dihentikan secara otomatis pada epoch ke-32 oleh mekanisme *early stopping*, dengan performa terbaik diperoleh pada epoch ke-22 yang menghasilkan *validation accuracy* sebesar 87,25%.



Gambar 4. Kurva Accuracy dan Loss Model InceptionV3 pada Fase *Feature Extraction* dan *Fine-Tuning*

Berdasarkan Gambar 4, kurva *training accuracy* dan *validation accuracy* menunjukkan pola konvergensi yang stabil. Peningkatan akurasi berlangsung secara konsisten pada awal pelatihan dan mulai mencapai kondisi stabil setelah memasuki *epoch* pertengahan. Selain itu, selisih antara akurasi pelatihan dan validasi relatif kecil, yang menunjukkan bahwa model mampu melakukan generalisasi dengan baik tanpa mengalami *overfitting* yang signifikan. Pada fase fine-tuning, sebanyak 62 layer teratas InceptionV3 dibuka kembali dengan *learning rate* sebesar 1×10^{-5} . Proses ini menyebabkan penurunan sementara pada *training accuracy* dan peningkatan *training loss* akibat penyesuaian ulang bobot model, namun performa kembali stabil pada *epoch* berikutnya dengan *validation accuracy* berada pada kisaran 84%–86%. Secara keseluruhan, kombinasi *transfer learning*, *augmentasi* data, regularisasi *dropout*, dan *fine-tuning* menghasilkan proses pelatihan yang stabil serta kemampuan generalisasi yang baik pada data validasi.

B. Hasil Evaluasi Model

Model InceptionV3 dievaluasi menggunakan 304 citra data uji yang tidak terlibat dalam proses pelatihan maupun validasi. Hasil evaluasi keseluruhan disajikan pada Tabel 6.

Tabel 6. Hasil Evaluasi Model InceptionV3

Metrik	Nilai
<i>Accuracy</i>	86,18%
<i>Precision</i>	86,46%
<i>Recall</i>	86,18%
<i>F1-Score</i>	86,23%


Berdasarkan Tabel 6, model memperoleh akurasi sebesar 86,18% dengan nilai *precision*, *recall*, dan *F1-score* yang relatif seimbang pada kisaran 86%. Hasil tersebut menunjukkan bahwa model mampu mengklasifikasikan penyakit daun tebu secara konsisten tanpa kecenderungan melakukan prediksi berlebihan maupun kehilangan banyak sampel pada kelas tertentu. Selain itu, nilai *F1-score* yang tinggi mengindikasikan bahwa model memiliki keseimbangan yang baik antara ketepatan prediksi dan kemampuan mengenali sampel yang relevan.

C. Analisis Performa Per Kelas

Analisis performa untuk masing-masing kelas penyakit disajikan pada Tabel 7 dan divisualisasikan pada Gambar 5.

Tabel 7. Hasil Evaluasi Per Kelas

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
<i>Mosaic</i>	0,91	0,83	0,87	70
<i>RedRot</i>	0,86	0,84	0,85	79
<i>Rust</i>	0,91	0,91	0,91	78
<i>Yellow</i>	0,79	0,87	0,83	77
<i>Accuracy</i>	-	-	0,86	304
<i>Macro Avg</i>	0,87	0,86	0,86	304
<i>Weighted Avg</i>	0,86	0,86	0,86	304




Gambar 5. Perbandingan *Precision*, *Recall*, dan *F1-Score* pada Setiap Kelas Penyakit Daun Tebu.

Berdasarkan Tabel 7 dan Gambar 5, kelas *Rust* menunjukkan performa terbaik dengan nilai *precision*, *recall*, dan *F1-score* sebesar 0,91, yang mengindikasikan bahwa karakteristik visual penyakit tersebut lebih mudah dibedakan dibandingkan kelas lainnya. Kelas *Mosaic* memiliki *precision* yang tinggi (0,91) namun *recall* lebih rendah (0,83), sedangkan kelas *Yellow* menunjukkan *recall* yang relatif tinggi (0,87) dengan *precision* terendah (0,79). Secara keseluruhan, seluruh kelas memperoleh nilai *F1-score* di atas 0,80 yang menunjukkan bahwa model mampu melakukan klasifikasi penyakit daun tebu secara konsisten pada setiap kelas yang diuji.

D. Analisis *Confusion Matrix*

Confusion matrix digunakan untuk menganalisis distribusi prediksi model pada setiap kelas penyakit daun tebu. Hasil *confusion matrix* ditunjukkan pada Gambar 6.



Gambar 6. Confusion Matrix Hasil Klasifikasi Penyakit Daun Tebu Menggunakan InceptionV3.

Berdasarkan Gambar 6, model berhasil mengklasifikasikan 58 dari 70 citra *Mosaic*, 66 dari 79 citra *RedRot*, 71 dari 78 citra *Rust*, dan 67 dari 77 citra *Yellow* secara benar. Kelas *Rust* menunjukkan jumlah prediksi benar tertinggi, sejalan dengan nilai *precision*, *recall*, dan *F1-score* terbaik pada evaluasi per kelas..

Kesalahan klasifikasi paling banyak terjadi antara kelas *RedRot* dan *Yellow*, dengan 8 citra *RedRot* diprediksi sebagai *Yellow* dan 7 citra *Yellow* diprediksi sebagai *RedRot*. Pola ini

mengindikasikan adanya kemiripan karakteristik visual antara kedua penyakit sehingga menyebabkan ambiguitas dalam proses klasifikasi. Selain itu, sejumlah kecil citra *Mosaic* juga salah diprediksi sebagai *Yellow*. Secara keseluruhan, dominasi nilai pada diagonal utama *confusion matrix* menunjukkan bahwa InceptionV3 berbasis *transfer learning* mampu mengenali sebagian besar sampel secara tepat dan membedakan karakteristik visual antarpenyakit daun tebu dengan baik, meskipun masih terdapat kesalahan klasifikasi pada kelas yang memiliki gejala serupa.

E. Pembahasan dan Komparasi dengan Penelitian Terdahulu

Hasil penelitian menunjukkan bahwa model InceptionV3 berbasis *transfer learning* mampu mengklasifikasikan penyakit daun tebu dengan akurasi sebesar 86,18% dan *F1-score* sebesar 86,23%. Hasil tersebut menunjukkan bahwa InceptionV3 mampu mengekstraksi karakteristik visual penyakit daun tebu secara efektif sehingga menghasilkan performa klasifikasi yang baik pada data yang belum pernah dilihat sebelumnya. Kemampuan tersebut didukung oleh arsitektur InceptionV3 yang memiliki mekanisme ekstraksi fitur multiskala sehingga mampu mengenali variasi warna, tekstur, dan pola gejala penyakit daun tebu secara lebih representatif. Temuan penelitian ini sejalan dengan Shafik dkk. [4] yang menyatakan bahwa *transfer learning* mampu meningkatkan performa klasifikasi penyakit tanaman pada dataset berukuran terbatas. Selain itu, hasil yang diperoleh juga mendukung penelitian Mazumder dkk. [5] yang menunjukkan bahwa pendekatan *transfer learning* dapat menghasilkan akurasi yang tinggi tanpa memerlukan jumlah data pelatihan yang sangat besar. Dibandingkan dengan penelitian Hu dkk. [6] yang menggunakan pendekatan *weighted ensemble* dan Mauya dkk. [8] yang menerapkan mekanisme *multiscale attention*, penelitian ini menghasilkan performa yang kompetitif dengan arsitektur yang lebih sederhana. Hasil tersebut menunjukkan bahwa InceptionV3 masih memiliki kemampuan yang baik dalam klasifikasi penyakit daun tebu tanpa memerlukan modifikasi model yang kompleks.

F. Keterbatasan Penelitian dan Rekomendasi

Penelitian ini masih memiliki beberapa keterbatasan. Dataset yang digunakan berasal dari satu sumber dengan jumlah 1.999 citra sehingga variasi kondisi lapangan, seperti perbedaan pencahayaan, latar belakang, dan kualitas pengambilan gambar, belum sepenuhnya terwakili. Selain itu, penelitian hanya mengevaluasi performa arsitektur InceptionV3 sehingga belum dapat memberikan perbandingan langsung dengan model *deep learning* lainnya. Untuk penelitian selanjutnya, disarankan menggunakan dataset yang lebih beragam dan merepresentasikan kondisi lapangan secara nyata. Selain itu, evaluasi terhadap arsitektur lain maupun pengembangan metode berbasis *attention* dan *ensemble* dapat dilakukan untuk meningkatkan kemampuan model dalam membedakan kelas penyakit yang memiliki karakteristik visual serupa.

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa InceptionV3 berbasis *transfer learning* mampu mengidentifikasi dan mengklasifikasikan penyakit daun tebu secara efektif dengan akurasi sebesar 86,18% serta *F1-score* sebesar 86,23%. Penerapan *transfer learning* memungkinkan model memanfaatkan representasi fitur yang telah dipelajari sebelumnya sehingga menghasilkan kemampuan klasifikasi yang baik pada dataset yang digunakan. Temuan ini menunjukkan bahwa InceptionV3 memiliki potensi untuk mendukung pengembangan sistem identifikasi penyakit daun tebu yang lebih cepat, konsisten, dan objektif, serta dapat menjadi

alternatif penerapan teknologi kecerdasan buatan dalam bidang pertanian untuk membantu proses monitoring kesehatan tanaman.

DAFTAR PUSTAKA

- [1] S. Thite, Y. Suryawanshi, K. Patil, and P. Chumchu, "Sugarcane leaf dataset: A dataset for disease detection and classification for machine learning applications," *Data Brief*, vol. 53, Apr. 2024, doi: 10.1016/j.dib.2024.110268.
- [2] S. D. Daphal and S. M. Koli, "Enhanced deep learning technique for sugarcane leaf disease classification and mobile application integration," *Heliyon*, vol. 10, no. 8, Apr. 2024, doi: 10.1016/j.heliyon.2024.e29438.
- [3] R. Sujatha, S. Krishnan, J. M. Chatterjee, and A. H. Gandomi, "Advancing plant leaf disease detection integrating machine learning and deep learning," *Sci. Rep.*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-024-72197-2.
- [4] W. Shafik, A. Tufail, C. De Silva Liyanage, and R. A. A. H. M. Apong, "Using transfer learning-based plant disease classification and detection for sustainable agriculture," *BMC Plant Biol.*, vol. 24, no. 1, Dec. 2024, doi: 10.1186/s12870-024-04825-y.
- [5] M. K. A. Mazumder, M. F. Mridha, S. Alfarhood, M. Safran, M. Abdullah-Al-Jubair, and D. Che, "A robust and light-weight transfer learning-based architecture for accurate detection of leaf diseases across multiple plants using less amount of images," *Front. Plant Sci.*, vol. 14, 2023, doi: 10.3389/fpls.2023.1321877.
- [6] K. Hu, H. Li, X. Fu, and S. Zhou, "Customized Weighted Ensemble of Modified Transfer Learning Models for the Detection of Sugarcane Leaf Diseases," *Electronics (Switzerland)*, vol. 13, no. 23, Dec. 2024, doi: 10.3390/electronics13234715.
- [7] S. Srinivasan, S. M. Prabin, S. K. Mathivanan, H. Rajadurai, S. Kulandaivelu, and M. A. Shah, "Sugarcane leaf disease classification using deep neural network approach," *BMC Plant Biol.*, vol. 25, no. 1, Dec. 2025, doi: 10.1186/s12870-025-06289-0.
- [8] J. Mauya, R. Amin, M. I. Hossain, S. Ruhi, and M. S. Reza, "Improved multiscale attention based deep learning approach for automated sugarcane leaf disease detection using BSRI data," *Sci. Rep.*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-28947-x.
- [9] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, NV, USA: IEEE, Jun. 2016, pp. 2818–2826. doi: 10.1109/CVPR.2016.308.
- [10] A. Mumuni and F. Mumuni, "Data augmentation: A comprehensive survey of modern approaches," Dec. 01, 2022, *Elsevier B.V.* doi: 10.1016/j.array.2022.100258.
- [11] G. Vrbančič and V. Podgorelec, "Transfer learning with adaptive fine-tuning," *IEEE Access*, vol. 8, pp. 196197–196211, 2020, doi: 10.1109/ACCESS.2020.3034343.
- [12] O. Rainio, J. Teuho, and R. Klén, "Evaluation metrics and statistical tests for machine learning," *Sci. Rep.*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-56706-x.