

OPTIMASI PIPELINE KLASIFIKASI PENYAKIT PADI MENGUNAKAN STRATEGI AUGMENTASI CITRA INTENSIF DAN TRANSFER LEARNING EFFICIENTNET-B0

¹Dwi Robiul R, ²Diyo Mollana F, ³Nanda S, ⁴Johan, ⁵Rahmad S, ⁶Satriyo W,
⁷Rika Rosnelly

^{1,2,3,4,5,6,7} Program Studi Ilmu Komputer

^{1,2,3,4,5,6,7} Universitas Potensi Utama

E-mail: ¹ dwirobiul@gmail.com, ² diyomollanafazri@gmail.com,

³ nanda.setiawansn27@gmail.com,

⁴ johanst1984@gmail.com, ⁵ rhmd.santoso290992@gmail.com,

⁶ satriyowibowol111@gmail.com, ⁷ rikarosnelly@gmail.com

ABSTRACT

*Rice plant diseases represent a significant challenge to global food productivity. This study aims to optimize a rice disease classification pipeline using the **EfficientNet-B0** architecture combined with **intensive image augmentation** strategies and transfer learning. The dataset comprises 10,407 rice leaf images categorized into 10 classes, including healthy conditions and nine types of diseases. Augmentation strategies such as random rotation, color jittering, and random resized cropping were implemented to enhance model robustness against diverse field conditions. Evaluation results demonstrate that the model achieved outstanding performance, with a **Top-1 Accuracy of 96.25%** and a **Top-5 Accuracy of 99.90%**. Grad-CAM++ analysis validated that the model accurately focuses feature extraction on pathological leaf areas. t-SNE visualization revealed clear feature cluster separation between classes, further supported by ROC curve AUC values reaching 1.00 for the majority of categories. This research confirms that the proposed pipeline is highly reliable for early rice disease detection and holds significant potential for mobile device implementation to assist farmers.*

Keywords: Rice Disease, EfficientNet-B0, Image Augmentation, Transfer Learning, Grad-CAM++.

ABSTRAK

Penyakit tanaman padi merupakan salah satu kendala utama dalam produktivitas pangan global. Penelitian ini bertujuan untuk mengoptimalkan pipeline klasifikasi penyakit padi menggunakan arsitektur **EfficientNet-B0** yang dikombinasikan dengan strategi **augmentasi citra intensif** dan *transfer learning*. Dataset yang digunakan mencakup 10.407 citra daun padi yang terbagi ke dalam 10 kategori, termasuk kondisi sehat dan sembilan jenis penyakit. Strategi augmentasi seperti rotasi acak, perubahan kontras, dan pemotongan citra diterapkan untuk meningkatkan ketangguhan model terhadap variasi kondisi di lapangan. Hasil evaluasi menunjukkan bahwa model mencapai performa yang

sangat luar biasa dengan **Akurasi Top-1 sebesar 96,25%** dan **Akurasi Top-5 sebesar 99,90%**. Analisis menggunakan Grad-CAM++ memvalidasi bahwa model secara akurat memfokuskan ekstraksi fitur pada area patologis daun. Visualisasi t-SNE menunjukkan pemisahan kluster fitur yang jelas antar kelas, didukung oleh nilai AUC pada kurva ROC yang mencapai 1,00 untuk mayoritas kategori. Penelitian ini membuktikan bahwa pipeline yang diusulkan sangat reliabel untuk deteksi dini penyakit padi dan potensial untuk diimplementasikan pada perangkat mobile bagi petani.

Kata Kunci: Penyakit Padi, EfficientNet-B0, Augmentasi Citra, *Transfer Learning*, Grad-CAM++.

PENDAHULUAN

Produksi padi merupakan komponen penting dalam ketahanan pangan global. Padi ditanam di lebih dari 100 negara dan menjadi sumber makanan utama bagi lebih dari 3 miliar orang di seluruh dunia (Reyes, 2023). Selain itu, produksi padi juga memiliki dampak signifikan terhadap pembangunan sosial-ekonomi, terutama di negara-negara berkembang (Manokaran et al., 2025).

Namun, produksi padi menghadapi berbagai tantangan, salah satunya adalah penyakit padi yang dapat mengurangi produktivitas secara signifikan. Penyakit-penyakit ini termasuk blas, hawar daun bakterial, bercak coklat, dan lain-lain, yang disebabkan oleh berbagai patogen seperti jamur, bakteri, dan virus (Adiyarta et al., 2020; Bajpai et al., 2023; Hota et al., 2025; Karakanti et al., 2024). Penyakit blast, misalnya, dapat mempengaruhi semua bagian tanaman padi yang berada di atas tanah, seperti daun, batang, dan panikel, yang mengakibatkan penurunan produktivitas (Ospanova et al., 2024).

Penyakit-penyakit ini tidak hanya mengurangi hasil panen tetapi juga mempengaruhi kualitas padi yang dihasilkan. Selain itu, penyakit-penyakit ini sering kali sulit dideteksi secara dini, yang membuat pengendalian dan pencegahan menjadi lebih menantang (Elmitwally et al., 2022).

Dalam beberapa tahun terakhir, teknologi pembelajaran mendalam (deep learning) dan transfer learning telah menunjukkan potensi besar dalam klasifikasi citra penyakit tanaman. Sejumlah penelitian telah dilakukan untuk mengembangkan sistem klasifikasi penyakit padi berbasis pengolahan citra dan convolutional neural network (CNN). Salah satu penelitian menggunakan pengoptimal ADAM, pembelajaran transfer (Inception V3, Xception), serta augmentasi data, dengan temuan bahwa model Xception dengan augmentasi data mencapai akurasi hingga 80% pada dataset kecil (Putra Setiawan et al., 2024). Penelitian lainnya menggunakan EfficientNetV2-S dengan augmentasi data berupa rotasi dan pembalikan, serta pengoptimal Adam, dan mencapai akurasi sebesar $95\% \pm 2$, menunjukkan peningkatan signifikan seiring penambahan data (Nggego et al., 2025).

Selain itu, model pembelajaran mendalam seperti VGG-16 dan GoogleNet telah diterapkan menggunakan validasi silang tiga kali lipat pada dataset yang lebih besar, dengan temuan bahwa VGG-16 dan GoogleNet masing-masing mencapai akurasi 92,24% dan 91,28% (Yakkundimath et al., 2022). Penelitian lainnya menguji berbagai arsitektur seperti Xception, DenseNet121, InceptionResNetV2, ResNet50V2, dan EfficientNetB0, di mana model Xception mencapai akurasi 99,99%, menegaskan efektivitas pembelajaran transfer dalam klasifikasi penyakit padi (Ali et al., 2024). Pada diagnosis penyakit blast secara otomatis, model ResNet50 dilaporkan mencapai akurasi tertinggi sebesar 99,75% (Shah et al., 2023).

Penelitian lain mengembangkan solusi seluler dengan memanfaatkan pembelajaran transfer dan jaringan adversarial generatif (GAN) untuk augmentasi data, menghasilkan akurasi sebesar 98,79% pada dataset yang telah diperluas (Kathiresan et al., 2021). Selain itu, penggunaan teknik regularisasi seperti putus sekolah (dropout) dan normalisasi batch pada model VGG16 dan ResNet50 menghasilkan akurasi masing-masing sebesar 100% dan 99,97% (Rakshit et al., 2025). Penelitian lainnya juga menunjukkan bahwa DenseNet121 mampu memberikan akurasi tinggi serta diagnosis yang efisien dalam klasifikasi penyakit padi (Bhuria, 2024).

Meskipun berbagai model seperti Xception, DenseNet, dan VGG telah digunakan secara luas, EfficientNet-B0 belum dieksplorasi secara ekstensif dalam konteks klasifikasi penyakit padi. Studi ini dapat mengisi celah tersebut dengan mengevaluasi secara spesifik kinerja EfficientNet-B0. Selain itu, banyak penelitian hanya menerapkan teknik augmentasi dasar seperti rotasi dan pembalikan citra, sehingga penelitian ini dapat mengeksplorasi strategi augmentasi yang lebih intensif untuk meningkatkan ketahanan model terhadap variasi data. Beberapa penelitian juga menggunakan kumpulan data berukuran kecil (misalnya 120 gambar [2]), sehingga penelitian ini dapat berkontribusi dengan menggunakan kumpulan data yang lebih besar dan lebih beragam guna meningkatkan kemampuan generalisasi model.

Dengan mengatasi kesenjangan ini, penelitian ini bertujuan untuk mengembangkan pipeline klasifikasi penyakit padi menggunakan strategi augmentasi citra intensif dan transfer learning dengan model EfficientNet-B0. Tujuan utama dari penelitian ini adalah :1) Mengidentifikasi dan mengklasifikasikan penyakit padi dengan akurasi tinggi menggunakan model EfficientNet-B0. 2) Meningkatkan kinerja model melalui strategi augmentasi citra intensif.(Abdulloh et al., 2024; Sarasati et al., 2024a; Tanny et al., 2025)

Penelitian ini diharapkan dapat memberikan kontribusi yang signifikan dalam pengembangan sistem klasifikasi penyakit padi berbasis pembelajaran mendalam yang lebih akurat, robust, dan aplikatif.

KAJIAN PUSTAKA

Klasifikasi Penyakit Padi

Klasifikasi penyakit padi merupakan aspek penting dalam pertanian untuk memastikan kesehatan tanaman dan meningkatkan hasil panen. Dengan kemajuan teknologi, metode berbasis visi komputer dan pembelajaran mendalam (deep learning) telah menjadi alat yang efektif untuk mendeteksi dan mengklasifikasikan penyakit tanaman secara otomatis (Rahman et al., 2024; Rose Anandhi & Sathiamoorthy, 2023).

Transfer Learning dalam Klasifikasi Penyakit Padi Transfer learning adalah teknik yang memanfaatkan model yang telah dilatih sebelumnya pada dataset besar dan kemudian disesuaikan untuk tugas spesifik. Model EfficientNet-B0, yang dikenal karena efisiensi dan akurasinya, telah digunakan secara luas dalam klasifikasi penyakit padi. Model ini menunjukkan kinerja yang unggul dalam berbagai studi, dengan akurasi mencapai hingga 99% (Abdulloh et al., 2024; Kohad et al., 2025; Sarasati et al., 2024b).

Augmentasi Citra untuk Meningkatkan Kinerja Model Augmentasi citra adalah teknik yang digunakan untuk meningkatkan jumlah dan keragaman data pelatihan dengan memodifikasi gambar asli. Teknik ini membantu model untuk lebih umum dan tahan terhadap variasi dalam data. Beberapa teknik augmentasi yang umum digunakan termasuk rotasi, flipping, penyesuaian kecerahan, dan penambahan noise (Nggego et al., 2025; Subburaman & Selvadurai, 2025; Talati et al., 2023). Dalam konteks klasifikasi penyakit padi, augmentasi citra telah terbukti meningkatkan akurasi model secara signifikan (Nggego et al., 2025; Subburaman & Selvadurai, 2025).


Implementasi EfficientNet-B0 dalam Klasifikasi Penyakit Padi EfficientNet-B0 telah diterapkan dalam berbagai penelitian untuk klasifikasi penyakit padi dengan hasil yang sangat baik. Model ini tidak hanya memberikan akurasi tinggi tetapi juga efisiensi komputasi yang lebih baik dibandingkan dengan model lain seperti VGG16, ResNet50, dan InceptionV3 (Kohad et al., 2025; Tanny et al., 2025; Verma et al., 2025). Dalam beberapa studi, penggunaan EfficientNet-B0 yang dikombinasikan dengan teknik augmentasi citra menghasilkan akurasi yang sangat tinggi, mencapai hingga 98.86% (Verma et al., 2025) .pa

METODE / ANALISIS PERANCANGAN

Desain Penelitian

Penelitian ini menggunakan pendekatan **eksperimen kuantitatif** untuk membangun dan mengevaluasi model klasifikasi citra penyakit padi berbasis **deep learning**. Model dibangun menggunakan arsitektur **EfficientNet-B0** dengan strategi **augmentasi citra**

intensif dan proses evaluasi komprehensif meliputi confusion matrix, ROC-AUC, t-SNE embedding, dan interpretabilitas GradCAM++.



Gambar 1 Flowchart Alur Penelitian

Secara umum, alur metodologi penelitian mengikuti tahapannya.

1. Pengumpulan dan pemahaman dataset
2. Pra-pemrosesan citra
3. Augmentasi citra
4. Pembentukan dataset PyTorch
5. Pemanggilan EfficientNet-B0
6. Pelatihan model
7. Pemilihan model terbaik
8. Evaluasi komprehensif
9. Visualisasi hasil analisis
10. Interpretabilitas model dengan GradCAM++

Dataset

Dataset berasal dari kumpulan citra penyakit padi yang disertai label kelas pada direktori:

- **train_images/**
- **train.csv**

Setiap baris pada *train.csv* memuat:

- Nama gambar (*image_id*)
- Label penyakit

Dataset berisi beberapa kelas penyakit:

['tungro', 'hispa', 'downy_mildew', 'bacterial_leaf_streak', 'bacterial_leaf_blight', 'brown_spot', 'blast', 'normal', 'dead_heart', 'bacterial_panicle_blight']

Pra-pemrosesan Data

Tahapan pra-pemrosesan dilakukan sebagai berikut:

- Membaca file CSV untuk mengambil nama gambar dan label.
- Membuat mapping label ke angka (label2id dan id2label).
- Konversi citra dari format BGR ke RGB menggunakan OpenCV.
- Resize citra menjadi ukuran 224×224 piksel sesuai kebutuhan EfficientNet.
- Normalisasi tensor melalui transform bawaan PyTorch.
- Error handling:

Jika gambar gagal dibaca, sistem mencoba mengakses citra lain sebagai fallback (5 kali percobaan).

Dataset dibagi menjadi:

- 90% untuk pelatihan
- 10% untuk validasi

Augmentasi Citra

Agar model lebih robust terhadap variasi kondisi lapangan, dilakukan **augmentasi citra intensif**, antara lain:

Tabel 1 Augmentasi Citra Intensif

No	Augmentasi	Fungsi Utama
1	Resize	Standardisasi ukuran
2	Horizontal Flip	Variasi orientasi
3	Vertical Flip	Variasi orientasi
4	Rotation	Variasi sudut gambar
5	Color Jitter	Variasi cahaya & warna
6	RandomResizedCrop	Variasi framing/crop
7	Normalize via ToTensor	Standardisasi data

Augmentasi dilakukan **setiap iterasi training**, sehingga model menerima variasi data berbeda setiap epoch.

Arsitektur Model

Model yang digunakan adalah **EfficientNet-B0**, yaitu CNN modern berbasis *compound scaling* yang menyeimbangkan kedalaman, lebar, dan resolusi.

Konfigurasi yang digunakan:

- Backbone: EfficientNet-B0 dari library timm

- Pretrained weights: False (baik digunakan jika dataset besar)
- Final classifier diganti menjadi Linear(n_features → jumlah kelas)
- Optimizer: (Anda bisa tambahkan Adam / SGD jika training block tersedia)
- Loss function: Cross Entropy Loss

Model di-load dari file **best_model.pth** yang dipilih berdasarkan akurasi terbaik selama pelatihan.

Proses Inferensi

Selama proses inferensi pada data validasi:

- a. Batch citra dikirim ke model.
- b. Model menghasilkan **logits**.
- c. Logits dikonversi menjadi **probabilitas** melalui Softmax.
- d. Probabilitas dikumpulkan untuk seluruh dataset validasi.
- e. Prediksi diambil menggunakan **argmax**.

Fungsi inferensi mengembalikan:

- logits
- probabilitas
- label ground truth

Evaluasi Model

Evaluasi dilakukan menggunakan beberapa metrik dan visualisasi berikut:

- a. Confusion Matrix
Menggambarkan distribusi benar–salah prediksi per kelas menggunakan *heatmap* (Seaborn).
- b. Classification Report
- c. Top-k Accuracy
- d. Visualisasi Prediksi Salah (Misclassified Images)
- e. ROC Curve dan AUC
- f. Visualisasi t-SNE Embedding
Ekstraksi fitur dari layer `forward_features()` EfficientNet untuk melihat distribusi embedding antar kelas dengan reduksi dimensi t-SNE.
- g. GradCAM++
Menerapkan GradCAM++ untuk memahami area citra yang memberikan kontribusi terbesar dalam pengambilan keputusan model. Visualisasi berupa heatmap yang diproyeksikan ke atas citra asli.

Perangkat dan Lingkungan Eksperimen

- Bahasa pemrograman: Python 3
- Framework deep learning: PyTorch
- Library model: timm
- Tools evaluasi: sklearn, Seaborn, Matplotlib
- GPU: (Kaggle Tesla P100/T4)

- Platform eksperimen: Kaggle Notebook

HASIL DAN PEMBAHASAN

1. Performa Klasifikasi Model

Eksperimen yang dilakukan menggunakan arsitektur EfficientNet-B0 menunjukkan efektivitas yang sangat tinggi dalam mendeteksi penyakit padi. Berdasarkan hasil evaluasi pada 1.041 data uji, model berhasil mencapai tingkat Akurasi Top-1 sebesar 96,25% dan Akurasi Top-5 mencapai 99,90%. Hal ini menunjukkan bahwa model tidak hanya akurat dalam prediksi utama, tetapi juga memiliki tingkat relevansi yang sangat tinggi dalam probabilitas lima besar kelas yang diprediksi.

Hasil metrik evaluasi secara mendalam disajikan dalam tabel berikut:


Tabel 2. Laporan Klasifikasi Performa Model

	precision	recall	f1-score	support
bacterial_leaf_blight	0.95	0.95	0.95	40
bacterial_leaf_streak	0.98	1.00	0.99	40
bacterial_panicle_blight	0.97	1.00	0.99	36
blast	0.98	0.92	0.95	168
brown_spot	0.97	0.96	0.96	89
dead_heart	1.00	0.99	1.00	147
downy_mildew	0.88	0.94	0.91	69
hispia	0.97	0.97	0.97	179
normal	0.97	0.97	0.97	162
tungro	0.92	0.96	0.94	111
accuracy			0.96	1041
macro avg	0.96	0.97	0.96	1041
weighted avg	0.96	0.96	0.96	1041

Akurasi Top-1: 96.25%
Akurasi Top-5: 99.90%

Secara keseluruhan, nilai *f1-score* rata-rata sebesar 0,96 menegaskan bahwa model memiliki performa yang stabil dan seimbang di seluruh kategori penyakit


2. Analisis Confusion Matrix



Gambar 2 Confusion Matrix

Gambar 2 menunjukkan Confusion Matrix yang menggambarkan distribusi prediksi model terhadap label sebenarnya. Dominasi warna biru gelap pada diagonal utama mengonfirmasi bahwa sebagian besar citra diklasifikasikan dengan tepat. Kelas Dead Heart menunjukkan performa hampir sempurna dengan 146 prediksi benar dari 147 sampel. Sedikit ambiguitas ditemukan pada kelas Downy Mildew, di mana beberapa sampel salah diprediksi sebagai Tungro. Hal ini disebabkan oleh kemiripan visual pada pola klorosis dan degradasi warna daun yang seringkali tumpang tindih pada kedua jenis penyakit tersebut.


3. Evaluasi Kemampuan Diskriminasi (ROC Curve)



Gambar 3 ROC Curve per Class

Kualitas klasifikasi lebih lanjut dibuktikan melalui kurva Receiver Operating Characteristic (ROC) pada Gambar 3. Hampir seluruh kategori penyakit menunjukkan nilai AUC (Area Under Curve) sebesar 1,00, kecuali kategori Downy Mildew yang memiliki nilai 0,99. Tingginya nilai AUC ini menjadi bukti bahwa model memiliki kemampuan diskriminasi yang sangat kuat dalam memisahkan fitur antar kelas penyakit tanpa mengalami banyak kesalahan false positive.


4. Visualisasi Sebaran Fitur (t-SNE)



Gambar 4. t-SNE Feature Distribution

Untuk membedah cara model memproses informasi, dilakukan visualisasi t-Distributed Stochastic Neighbor Embedding (t-SNE). Gambar 4 memperlihatkan bahwa model berhasil memetakan fitur-fitur gambar ke dalam kluster yang terpisah secara jelas sesuai dengan label kelasnya. Pemisahan ruang fitur yang bersih ini menjelaskan mengapa EfficientNet-B0 sangat efektif; model mampu mengekstraksi karakteristik unik yang sangat spesifik dari tiap penyakit padi, sehingga meminimalkan kebingungan klasifikasi.


5. Interpretasi Visual Menggunakan Grad-CAM++



Gambar 5. Visualisasi GradCAM++

Guna memastikan transparansi dan akuntabilitas keputusan AI, diterapkan teknik Grad-CAM++. Gambar 5 menunjukkan hasil peta panas (heatmap) di mana area berwarna merah (fokus tertinggi model) berada tepat pada lesi atau bercak penyakit di permukaan daun. Hal ini memvalidasi bahwa model benar-benar mempelajari fitur patologis tanaman dan tidak terpengaruh oleh noise atau latar belakang gambar, sehingga hasil klasifikasi ini secara agrikultur dapat dipertanggungjawabkan.

6. Analisis Kesalahan Prediksi



Gambar 6 Contoh Prediksi Salah

Meskipun mencapai akurasi tinggi, analisis terhadap Gambar 6 (Contoh Prediksi Salah) menunjukkan beberapa keterbatasan model. Kesalahan klasifikasi, seperti penyakit Blast yang terdeteksi sebagai Hispa, umumnya terjadi pada gambar dengan kualitas pencahayaan yang ekstrem atau gejala penyakit yang masih sangat dini. Hal ini menjadi catatan penting untuk pengembangan model di masa depan, terutama dalam menangani data dengan noise visual yang tinggi di lapangan.

KESIMPULAN

Berdasarkan hasil penelitian dan pembahasan, dapat disimpulkan bahwa implementasi arsitektur EfficientNet-B0 yang dikombinasikan dengan strategi augmentasi citra intensif terbukti sangat efektif dalam mengklasifikasikan penyakit pada tanaman padi. Penelitian ini menghasilkan beberapa temuan utama:

1. Akurasi Tinggi: Model berhasil mencapai tingkat Akurasi Top-1 sebesar 96,25% dan Akurasi Top-5 mencapai 99,90% pada data validasi. Hal ini menunjukkan bahwa model memiliki tingkat presisi yang sangat tinggi dalam mendeteksi 10 kategori kondisi padi, termasuk penyakit yang memiliki kemiripan visual.
2. Stabilitas dan Generalisasi: Melalui analisis kurva akurasi dan *loss*, model menunjukkan proses konvergensi yang stabil tanpa adanya indikasi *overfitting*. Penggunaan *Transfer Learning* mempercepat proses pembelajaran sementara teknik augmentasi meningkatkan kemampuan generalisasi model terhadap variasi pencahayaan dan sudut pengambilan gambar.
3. Transparansi Keputusan AI: Visualisasi menggunakan Grad-CAM++ mengonfirmasi bahwa model mengambil keputusan klasifikasi berdasarkan fitur patologis yang relevan (lesi pada daun), bukan berdasarkan latar belakang gambar. Hal ini diperkuat dengan analisis t-SNE yang menunjukkan terbentuknya kluster fitur yang terpisah secara jelas antar tiap kelas penyakit.
4. Reliabilitas Evaluasi: Nilai AUC pada ROC Curve yang mencapai 1,00 untuk mayoritas kelas membuktikan kemampuan diskriminasi model yang hampir sempurna. Meskipun terdapat sedikit hambatan pada kelas *Downy Mildew* karena kemiripan tekstur, nilai rata-rata F1-Score sebesar 0,96 menegaskan bahwa sistem ini sangat reliabel untuk digunakan sebagai alat bantu deteksi dini di sektor pertanian.

Secara keseluruhan, pipeline klasifikasi ini siap diimplementasikan ke dalam perangkat berbasis mobile atau *edge computing* untuk membantu petani melakukan diagnosis penyakit padi secara cepat dan akurat di lapangan.

DAFTAR PUSTAKA

- Abdulloh, F. F., Apriliandika, W., Aminuddin, A., Tusher, E. H., Asaddulloh, B. P., & Rahardi, M. (2024). *EfficientNet-B0 and YOLOv8 Models with Adam Optimizer for Rice Leaf Disease Classification*. 521–526. Scopus. <https://doi.org/10.1109/BTS-I2C63534.2024.10942011>
- Adiyarta, K., Zonyfar, C., & Fatimah, T. (2020). *Identification of rice leaf disease based on rice leaf image features using the k-Nearest Neighbour (k-NN) technique*. 160–165. Scopus. <https://doi.org/10.5220/0008931101600165>
- Ali, M. H., Mahmud, T., Mim, S. J., Aziz, M. T., Hossain, M. S., & Andersson, K. (2024). *Leveraging Transfer Learning for Accurate Detection of Diseases in Rice Leaf Images*. 2024 IEEE Conference on Computing Applications and Systems, COMPAS 2024. Scopus. <https://doi.org/10.1109/COMPAS60761.2024.10796309>
- Bajpai, A., Tiwari, N. K., Tripathi, A. K., Tripathi, V., & Katiyar, D. (2023). *Early leaf diseases prediction in Paddy crop using Deep learning model*. 2023 2nd International Conference on Paradigm Shifts in Communications Embedded Systems, Machine Learning and Signal Processing, PCEMS 2023. Scopus. <https://doi.org/10.1109/PCEMS58491.2023.10136038>
- Bhuria, R. (2024). *Agricultural Innovation: Leveraging DenseNet-121 for Superior Paddy Disease Management*. 657–661. Scopus. <https://doi.org/10.1109/ICTACS62700.2024.10840504>
- Elmitwally, N. S., Tariq, M., Khan, M. A., Ahmad, M., Abbas, S., & Alotaibi, F. M. (2022). *Rice Leaves Disease Diagnose Empowered with Transfer Learning*. *Computer Systems Science and Engineering*, 42(3), 1001–1014. Scopus. <https://doi.org/10.32604/csse.2022.022017>
- Hota, S., Mukherjee, A. K., Naik, S. K., & Mohapatra, P. K. (2025). *Priming with Trichoderma for induction of defense against rice pathogens*. *Cereal Research Communications*. Scopus. <https://doi.org/10.1007/s42976-025-00705-9>
- Karakanti, S., Veerubhotla, S. R. K. S., & Chalamalasetti, R. (2024). *Analysis of Machine Learning Models Used to Diagnose Rice Plant Diseases-A Review*. *International Journal of Intelligent Systems and Applications in Engineering*, 12(1), 87–94. Scopus. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85182472547&partnerID=40&md5=03d4459d36dce56acc5b5a0ce03a30>
- Kathiresan, G., Anirudh, M., Nagharjun, M., & Karthik, R. (2021). *Disease detection in rice leaves using transfer learning techniques*. 1911(1). Scopus. <https://doi.org/10.1088/1742-6596/1911/1/012004>
- Kohad, R., Yadav, S. K., Choudhary, S., Sawardekar, S., Shirsath, M., & Borate, V. (2025). *Rice Leaf Disease Classification with Advanced Resizing and Augmentation*. 2025 International Conference on Recent Advances in Electrical, Electronics, Ubiquitous Communication, and Computational Intelligence, RAEEUCCI 2025. Scopus. <https://doi.org/10.1109/RAEEUCCI63961.2025.11048331>
- Manokaran, A. K., Marimuthu, R., Sellaperumal, P., Selvaraj, S., Rathinavelu, S., Kaliaperumal, R., & Vellaiyadevan, K. (2025). *A review on adaptive water*

- management for climate-resilient rice: Mitigating greenhouse gas (GHG) emissions. *Plant Science Today*, 12(2). Scopus. <https://doi.org/10.14719/pst.6988>
- Nggego, D. A., Hasbi, M., & Patawaran, N. (2025). *Data augmentation and transfer learning efficientnetv2-s on rice leaf disease classification*. 1454(1). Scopus. <https://doi.org/10.1088/1755-1315/1454/1/012001>
- Ospanova, A., Mynbayeva, D., Turganova, C., Usenbekov, B., Amirova, A., Berkimbay, K., Zhunusbayeva, Z., & Utepbergenov, E. (2024). *Molecular screening for the presence of Magnaporthe oryzae resistance Pi-b gene in rice hybrids*. 100. Scopus. <https://doi.org/10.1051/bioconf/202410003012>
- Putra Setiawan, N. R., Wulandhari, L. A., & Alam, I. N. (2024). *Rice Plant Disease Recognition Based on Convolutional Neural Network with Transfer Learning and Data Augmentation*. 259–264. Scopus. <https://doi.org/10.1109/ICIMCIS63449.2024.10957476>
- Rahman, N., Jashim, F. B., & Sultana, Z. (2024). *Classification of rice leaf disease with cutting-edge deep learning models*. 333–338. Scopus. <https://doi.org/10.1109/ICECE64886.2024.11024664>
- Rakshit, S. V., Chowdhury, A. M. M. M. I., Chakma, A., Hasan, I., Roy, S., & Rahman, T. (2025). *DeepLeafDiagnosis: A Two-Phase Transfer Learning Strategy for Perfect Accuracy in Rice Leaf Disease Classification*. 2025 IEEE International Conference on Quantum Photonics, Artificial Intelligence, and Networking, QPAIN 2025. Scopus. <https://doi.org/10.1109/QPAIN66474.2025.11172163>
- Reyes, V. P. (2023). Fantastic genes: Where and how to find them? Exploiting rice genetic resources for the improvement of yield, tolerance, and resistance to a wide array of stresses in rice. *Functional and Integrative Genomics*, 23(3). Scopus. <https://doi.org/10.1007/s10142-023-01159-0>
- Rose Anandhi, D. F., & Sathiamoorthy, S. (2023). *Deep Learning based Automated Rice Plant Disease Recognition and Classification Model*. 2023 1st International Conference on Advances in Electrical, Electronics and Computational Intelligence, ICAEECI 2023. Scopus. <https://doi.org/10.1109/ICAEECI58247.2023.10370809>
- Sarasati, F., Agustina, C., Astuti, W., Wahyudi, T., & Pratama, E. A. (2024a). *Enhancing Rice Disease Detection with K-Means Segmentation and Comparison of EfficientNetB0, ResNet50, and Xception*. 365–370. Scopus. <https://doi.org/10.1109/ICITRI62858.2024.10699083>
- Sarasati, F., Agustina, C., Astuti, W., Wahyudi, T., & Pratama, E. A. (2024b). *Enhancing Rice Disease Detection with K-Means Segmentation and Comparison of EfficientNetB0, ResNet50, and Xception*. 365–370. Scopus. <https://doi.org/10.1109/ICITRI62858.2024.10699083>
- Shah, S. R., Qadri, S., Bibi, H., Shah, S. M. W., Sharif, M. I., & Marinello, F. (2023). Comparing Inception V3, VGG 16, VGG 19, CNN, and ResNet 50: A Case Study on Early Detection of a Rice Disease. *Agronomy*, 13(6). Scopus. <https://doi.org/10.3390/agronomy13061633>
- Subburaman, G., & Selvadurai, M. V. (2025). A novel approach to enhance rice foliar disease detection: Custom data generators, advanced augmentation, hybrid fine-tuning, and regularization techniques with DenseNet121. *IAES International*

- Journal of Robotics and Automation*, 14(2), 237–247. Scopus. <https://doi.org/10.11591/ijra.v14i2.pp237-247>
- Talati, T., Bhat, A., & Kalbande, D. (2023). *Effects of Image Augmentation Techniques for Rice Leaf Disease Detection*. 2023 3rd International Conference on Intelligent Technologies, CONIT 2023. Scopus. <https://doi.org/10.1109/CONIT59222.2023.10205782>
- Tanny, M. T. Y., Biswas, M. E., Akter, A., Modok, C. K., Nipu, M. H. N., Hasan, M., Hossain, M. D., Mandal, A. K., Hossain, M. S., & Sultana, T. (2025). *Customized EfficientNet: A Transfer Learning Approach for Rice Leaf Disease Classification with Advanced Resizing and Augmentation*. 2025 International Conference on Electrical, Computer and Communication Engineering, ECCE 2025. Scopus. <https://doi.org/10.1109/ECCE64574.2025.11013880>
- Verma, P. R., Pantola, D., & Singh, N. P. (2025). *An Optimal Framework for Rice Leaf Disease Prediction Using Mixed Precision and Gradient-Weighted Class Activation Mapping*. 1436 LNNS, 75–84. Scopus. https://doi.org/10.1007/978-981-96-7134-2_6
- Yakkundimath, R., Saunshi, G., Anami, B., & Palaiah, S. (2022). Classification of Rice Diseases using Convolutional Neural Network Models. *Journal of The Institution of Engineers (India): Series B*, 103(4), 1047–1059. Scopus. <https://doi.org/10.1007/s40031-021-00704-4>