TECHNOVATAR Jurnal Teknologi, Industri dan Informasi
Vol. 2, No. 3, Juli 2024, pp. 1 – 14
Open Access:
https://journal.awatarapublisher.com/index.php/technovatar
ISSN: 3031-8874, DOI: 10.61434/technovatar.v2i3.393

KLASIFIKASI PENYAKIT DAUN PADI MENGGUNAKAN RESNET50 DENGAN MODIFIKASI KEPALA KLASIFIKASI DAN AUGMENTASI DATA

Mohamad Firdaus[1*], Ari Fiandi[2], Indah Rizkika[3], Dimas Dwi Rianto[4]
[1, 2, 3, 4] Program Studi Informatika, Fakultas Teknik, Institut Teknologi dan Kesehatan Mahardika, Cirebon, Indonesia

INFO ARTIKEL
Sejarah Artikel:
Diterima, 8 Juli 2024
Direvisi, 15 Juli 2024
Disetujui, 8 Agustus 2024

KEYWORDS
Deep learning
Convolutional neural network
ResNet50
Data augmentation
Rice leaf disease

ABSTRACT

Rice leaf diseases threaten paddy productivity. This study compares ResNet50 classification heads and data augmentation for five rice leaf image classes: Bacterial Leaf Blight, Tungro, Normal, Brown Spot, and Blast. A public Kaggle dataset of 6,034 images was used, with 250 stratified images reserved for testing. Eight scenarios (S1–S8) compared ResNet50 with and without intermediate multilayer perceptron (MLP) layers under baseline, single-augmentation, and combined-augmentation settings. Accuracy and macro-averaged precision, recall, and F1-score were evaluated. Removing the intermediate MLP layers increased baseline accuracy from 88.40% (S1) to 89.20% (S3). Among single augmentations for the architecture without MLP, Random Zoom achieved the highest accuracy (92.40%). S8, combining the architecture without MLP with four augmentations, achieved 94.40% accuracy, 94.68% macro-precision, 93.84% macro-recall, and 94.23% macro-F1, a 6.00 percentage-point increase over S1. These findings are descriptive results on the reported test set. The incomplete factorial design and absence of reported repeated runs, statistical testing, and external field validation limit conclusions about architecture–augmentation interactions and generalization. Further documentation of training settings and independent validation are required before field deployment.

This work is licensed under a Creative Commons Attribution 4.0 International License.

KATA KUNCI
Deep learning
Convolutional neural network
ResNet50
Augmentasi data
Penyakit daun padi

CORRESPONDING AUTHOR
Mohamad Firdaus
Program Studi Informatika, Fakultas Teknik, Institut Teknologi dan Kesehatan Mahardika
Jl. Taman Pemuda No. 2, Cirebon 45153, Jawa Barat, Indonesia
Email: firdaus@itekesmahardika.ac.id

ABSTRAK

Penyakit daun padi mengancam produktivitas padi. Penelitian ini membandingkan kepala klasifikasi ResNet50 dan augmentasi data untuk lima kelas citra: Bacterial Leaf Blight, Tungro, Normal, Brown Spot, dan Blast. Dataset publik Kaggle berisi 6.034 citra digunakan, dengan 250 citra dipisahkan secara terstratifikasi untuk pengujian. Delapan skenario (S1–S8) membandingkan ResNet50 dengan dan tanpa lapisan antara multilayer perceptron (MLP), tanpa augmentasi, dengan augmentasi tunggal, dan dengan gabungan augmentasi. Evaluasi memakai accuracy serta precision, recall, dan F1-score rata-rata makro. Penghapusan lapisan antara MLP meningkatkan accuracy dasar dari 88,40% (S1) menjadi 89,20% (S3). Di antara augmentasi tunggal pada arsitektur tanpa MLP, Random Zoom memberikan accuracy tertinggi (92,40%). S8, yaitu arsitektur tanpa MLP dengan empat augmentasi, mencapai accuracy 94,40%, macro-precision 94,68%, macro-recall 93,84%, dan macro-F1 94,23%, meningkat 6,00 poin persentase dari S1. Temuan ini merupakan hasil deskriptif pada data uji yang dilaporkan. Rancangan yang bukan faktorial lengkap serta belum dilaporkannya pengulangan, uji statistik, dan validasi lapangan eksternal membatasi kesimpulan mengenai interaksi arsitektur–augmentasi dan generalisasi. Dokumentasi konfigurasi pelatihan dan validasi independen diperlukan sebelum penerapan lapangan.

PENDAHULUAN

Padi merupakan sumber pangan utama bagi lebih dari separuh penduduk dunia (Fukagawa & Ziska, 2019). Penyakit daun, termasuk Bacterial Leaf Blight, Tungro, Brown Spot, dan Blast, menjadi sasaran penting pengenalan berbasis citra karena gejalanya tampak pada warna, bercak, dan kerusakan jaringan daun (Goluguri dkk., 2021; Jiang dkk., 2020; Shah dkk., 2016). Pemeriksaan visual bergantung pada pengalaman pengamat, sehingga klasifikasi citra dapat membantu penyaringan awal kasus yang memerlukan pemeriksaan lebih lanjut. Namun, keberhasilan pada dataset penelitian perlu dibedakan dari kemampuan diagnosis pada kondisi lapangan.

Convolutional neural network (CNN) mempelajari fitur visual secara hierarkis dan telah digunakan untuk klasifikasi penyakit padi (Ahad dkk., 2023; Latif dkk., 2022; Rahman dkk., 2020). ResNet menggunakan residual connection untuk mendukung pelatihan jaringan dalam (He dkk., 2016). Pada ResNet50, fitur dari backbone dapat diringkas melalui global average pooling (GAP), kemudian dipetakan ke kelas keluaran. Penambahan lapisan dense antara membentuk kepala klasifikasi multilayer perceptron (MLP). Penelitian ini memodifikasi kepala klasifikasi tersebut; susunan blok residual pada backbone tetap menjadi acuan ResNet50. Dengan demikian, istilah tanpa MLP merujuk pada penghapusan lapisan dense antara, bukan penghapusan lapisan keluaran.

Penelitian terdahulu mengembangkan beragam pendekatan klasifikasi penyakit padi. Lu dkk. (2017) menguji CNN pada 500 citra untuk sepuluh penyakit, sedangkan Latif dkk. (2022) menggunakan modifikasi VGG19 untuk enam kelas. Paddy Doctor menyediakan 16.225 citra dalam 13 kelas dan melaporkan F1-score 97,50% pada ResNet34 (Petchiammal, Briskline Kiruba, dkk., 2023). PaddyNet selanjutnya melaporkan accuracy 98,99% pada dataset 13 kelas (Petchiammal, Murugan, dkk., 2023). Pendekatan lain meliputi ansambel CNN (Deng dkk., 2021), CNN-BiGRU (Lu dkk., 2023), transfer learning (Simhadri & Kondaveeti, 2023), dan DeepRice (Ritharson dkk., 2024). Model hibrida, arsitektur ringan, serta variasi pelatihan juga diteliti oleh Cui dan Tan (2023), Dixit dan Verma (2023), Dogra dkk. (2023), Gupta dkk. (2023), Jesie dkk. (2024), Khan dkk. (2023), Liu dkk. (2023), Prathima dkk. (2023), dan C. Zhang dkk. (2023). Keragaman dataset dan protokol tersebut membuat angka kinerja lintas studi tidak dapat diperlakukan sebagai perbandingan langsung.

Augmentasi memperluas variasi data latih melalui transformasi geometris dan fotometrik, termasuk perubahan skala, kecerahan, serta pembalikan citra (Shorten & Khoshgoftaar, 2019). Penerapannya pada pengenalan penyakit padi telah dilaporkan oleh Ahad dkk. (2023), Bari dkk. (2021), Rahman dkk. (2020), dan Sethy dkk. (2020). Pertanyaan yang dikaji di sini adalah bagaimana kinerja kepala klasifikasi dengan dan tanpa lapisan MLP berubah ketika diberi perlakuan augmentasi yang berbeda pada subset data yang sama. Fokus ini menyediakan perbandingan internal yang lebih terarah daripada menyimpulkan keunggulan model dari angka pada dataset yang berbeda.

Penelitian ini bertujuan membandingkan dua kepala klasifikasi ResNet50 tanpa augmentasi, mengukur perubahan kinerja ketika Random Zoom diterapkan pada kedua kepala, serta membandingkan empat augmentasi tunggal dan gabungannya pada kepala tanpa MLP. Delapan skenario digunakan untuk mengidentifikasi konfigurasi dengan accuracy tertinggi terhadap target 90%. Ruang lingkup mencakup empat kelas penyakit dan satu kelas Normal dari dataset Kaggle. Evaluasi dibatasi pada klasifikasi citra dalam subset tersebut, bukan pengujian diagnosis lapangan atau interaksi faktorial lengkap antara seluruh arsitektur dan augmentasi.

METODE PENELITIAN

Penelitian eksperimen dilakukan pada periode Agustus 2023 hingga Maret 2024 di Laboratorium Komputer Program Studi Informatika Institut Teknologi dan Kesehatan (ITEKes) Mahardika, Cirebon. Alur penelitian meliputi pemilihan subset dataset, pemisahan citra uji, prapemrosesan, augmentasi data latih, pembentukan delapan konfigurasi model, pelatihan, serta evaluasi berbasis confusion matrix. Gambar 1 memperjelas bahwa augmentasi diterapkan pada cabang data latih, sedangkan data validasi dan uji tidak diberi augmentasi pelatihan.

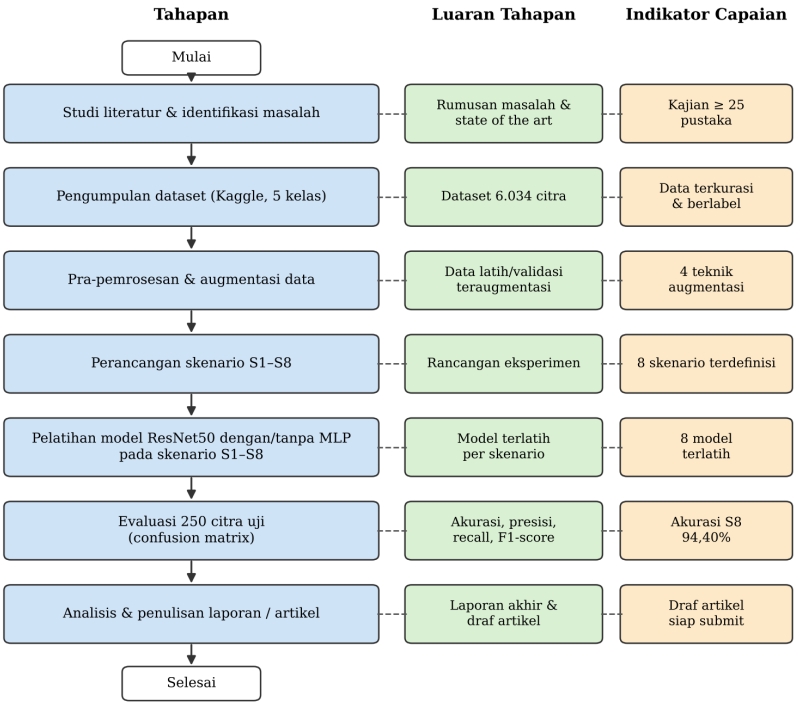

Gambar 1 Diagram alir prosedur penelitian

Data berasal dari kompetisi Paddy Doctor: Paddy Disease Classification pada Kaggle (Paddy Doctor, 2022). Kompetisi menyediakan 10.407 citra berlabel dalam sepuluh

kelas; penelitian ini memakai subset 6.034 citra dari lima kelas: Bacterial Leaf Blight, Tungro, Normal, Brown Spot, dan Blast. Subset penelitian ini juga perlu dibedakan dari keseluruhan dataset Paddy Doctor berisi 16.225 citra dan 13 kelas yang dilaporkan Petchiammal, Briskline Kiruba, dkk. (2023). Contoh citra disajikan pada Gambar 2. Seluruh citra diubah ukurannya menjadi 224 × 224 piksel dan dinormalisasi. Sebanyak 250 citra dipisahkan secara terstratifikasi untuk pengujian; 5.784 citra sisanya dialokasikan untuk pelatihan dan validasi. Distribusi jumlah citra dan alokasi uji per kelas dirinci pada Tabel 2.

Pembagian terstratifikasi mempertahankan representasi kelas pada data uji. Evaluasi ini menggunakan 250 citra uji internal yang dipisahkan dari subset penelitian, bukan 3.469 citra uji tanpa label pada kompetisi Kaggle. Rincian proporsi latih dan validasi, seed pemisahan, dan audit duplikasi dibahas sebagai batas reproduksibilitas pada bagian keterbatasan.

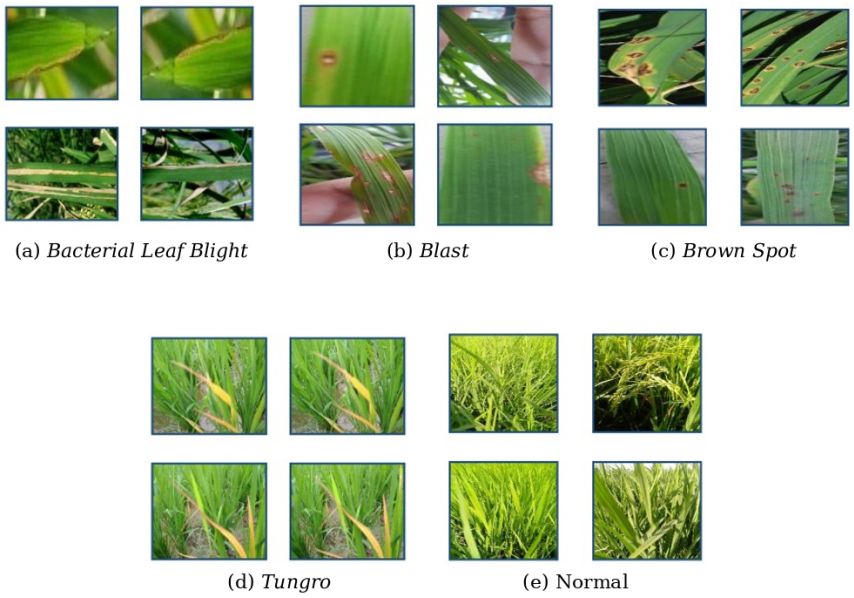

Gambar 2 Contoh citra lima kelas pada subset penelitian

Empat perlakuan augmentasi diterapkan hanya pada data latih: Random Zoom dengan rentang parameter [1,5; 2,0], Random Brightness dengan rentang [1,2; 2,0], serta Horizontal Flip dan Vertical Flip dengan probabilitas masing-masing 0,5. Nilai tersebut mempertahankan konfigurasi eksperimen yang dilaporkan. Zoom dan brightness memvariasikan skala serta kecerahan, sedangkan flip memvariasikan orientasi. Data validasi dan uji mengikuti prapemrosesan ukuran dan normalisasi tanpa augmentasi pelatihan.

Arti numerik rentang augmentasi bergantung pada API yang digunakan; karena itu, nilai tersebut tidak ditafsirkan sebagai parameter dari library tertentu. Implementasi library,

urutan komposisi, dan skema online atau offline belum dapat direkonstruksi dari dokumentasi eksperimen yang tersedia.

Peubah bebas penelitian adalah susunan kepala klasifikasi dan perlakuan augmentasi. Pada konfigurasi dengan MLP, fitur backbone ResNet50 diringkas melalui GAP, kemudian diproses oleh Dense(1024, ReLU), Dense(512, ReLU), dan Dense(256, ReLU), sebelum menuju Dense(5, Softmax). Pada konfigurasi tanpa MLP, fitur GAP langsung dihubungkan ke Dense(5, Softmax). Gambar 3 dan Gambar 4 menggambarkan kedua susunan tersebut. Backbone tidak diganti dengan arsitektur baru; modifikasi dilakukan pada pemetaan fitur menuju keluaran lima kelas. Delapan skenario dirinci pada Tabel 1.

S1 dan S3 menjadi pembanding tanpa augmentasi untuk masing-masing kepala klasifikasi. S2 dan S4 menggunakan Random Zoom, sehingga perubahan terkait zoom dapat dibandingkan terhadap baseline kepala yang bersesuaian. S5–S7 mengevaluasi augmentasi tunggal lain pada kepala tanpa MLP, sedangkan S8 menggabungkan empat augmentasi. Rancangan ini tidak mencakup seluruh kombinasi perlakuan pada kepala dengan MLP.

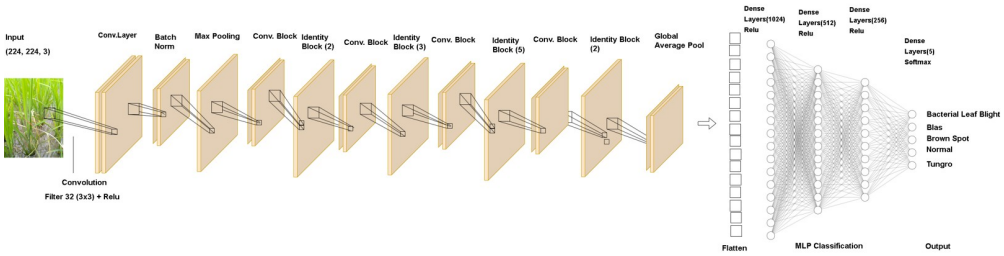

Gambar 3 Arsitektur ResNet50 dengan kepala klasifikasi MLP (S1–S2)

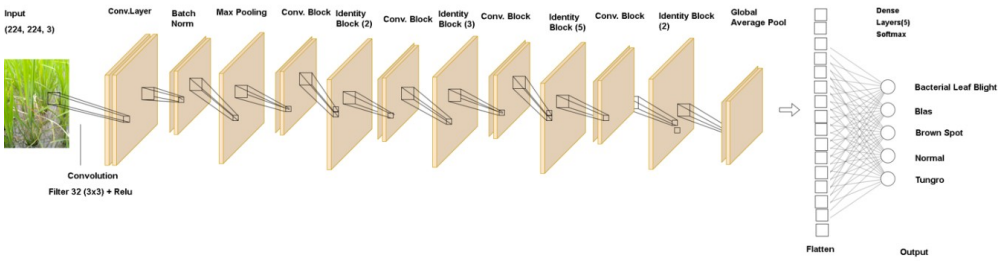

Gambar 4 Arsitektur ResNet50 tanpa MLP (S3–S8)

Tabel 1 Skenario eksperimen penelitian

Skenario	Arsitektur / Perlakuan
S1	ResNet50 (dengan MLP), tanpa augmentasi
S2	ResNet50 + Random Zoom
S3	ResNet50 – MLP, tanpa augmentasi
S4	ResNet50 – MLP + Random Zoom
S5	ResNet50 – MLP + Random Brightness

Skenario	Arsitektur / Perlakuan
S6	ResNet50 – MLP + Horizontal Flip
S7	ResNet50 – MLP + Vertical Flip
S8	ResNet50 – MLP + seluruh augmentasi (zoom, brightness, horizontal flip, vertical flip)

Kinerja dievaluasi menggunakan accuracy dan precision, recall, serta F1-score rata-rata makro agar kontribusi setiap kelas tetap diperhatikan. Untuk matriks C dengan baris kelas aktual dan kolom prediksi, Accuracy = Σ C_kk / N. Bagi kelas k, TP_k = C_kk, FN_k = Σ_j C_kj − C_kk, dan FP_k = Σ_i C_ik − C_kk. Selanjutnya, Precision_k = TP_k / (TP_k + FP_k), Recall_k = TP_k / (TP_k + FN_k), dan F1_k = 2TP_k / (2TP_k + FP_k + FN_k). Nilai makro dihitung sebagai rata-rata aritmetika kelima nilai per kelas. Seluruh metrik dinyatakan dalam persen. Selisih accuracy dinyatakan dalam poin persentase, bukan persentase relatif. Karena N = 250, satu prediksi benar setara dengan 0,40 poin persentase accuracy.

HASIL DAN PEMBAHASAN

Subset penelitian berisi 6.034 citra dengan distribusi kelas yang tidak seimbang (Tabel 2). Normal mencakup 1.764 citra (29,23%), Blast 1.738 (28,80%), Tungro 1.088 (18,03%), Brown Spot 965 (15,99%), dan Bacterial Leaf Blight 479 (7,94%). Alokasi uji sebanyak 20, 45, 73, 40, dan 72 citra mengikuti proporsi masing-masing kelas, dengan total 250 citra. Jumlah citra di luar subset uji dapat dihitung sebagai selisih jumlah kelas dan alokasi uji; angka ini merupakan gabungan latih dan validasi, bukan jumlah data latih saja.

Tabel 2 Distribusi dataset berdasarkan kelas dan alokasi data uji

No.	Kelas Citra	Jumlah Citra	Persentase (%)	Data Uji
1	Bacterial Leaf Blight	479	7,94	20
2	Tungro	1.088	18,03	45
3	Normal	1.764	29,23	73
4	Brown Spot	965	15,99	40
5	Blast	1.738	28,80	72
Total	Seluruh Kelas	6.034	100,00	250

Tabel 3 menunjukkan kinerja delapan skenario. Accuracy tertinggi diperoleh S8 sebesar 94,40%, dengan macro-precision 94,68%, macro-recall 93,84%, dan macro-F1 94,23%. S1 menghasilkan accuracy terendah, 88,40%, sedangkan S3 tanpa MLP mencapai 89,20%. Hasil ini menggambarkan perbedaan pada data uji, bukan bukti signifikansi statistik. Perbandingan tanpa augmentasi S1–S3 hanya berbeda dua prediksi benar dari 250 citra; karena itu, kenaikan 0,80 poin persentase perlu ditafsirkan secara proporsional.

Tabel 3 Hasil pengujian delapan skenario eksperimen

Skenario	Arsitektur / Perlakuan	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
S1	ResNet50	88,40	88,72	87,96	88,18
S2	ResNet50 + Random Zoom	90,80	91,06	90,21	90,55
S3	ResNet50 – MLP	89,20	89,48	88,76	89,10
S4	ResNet50 – MLP + Random Zoom	92,40	92,67	91,88	92,26
S5	ResNet50 – MLP + Random Brightness	91,20	91,53	90,74	91,12
S6	ResNet50 – MLP + Horizontal Flip	90,40	90,76	89,95	90,31
S7	ResNet50 – MLP + Vertical Flip	89,60	89,94	89,12	89,51
S8	ResNet50 – MLP + seluruh augmentasi	94,40	94,68	93,84	94,23

Tabel 4 menambahkan jumlah prediksi benar serta perubahan accuracy terhadap S1 dan S3. Dibandingkan S1, S8 menghasilkan 15 prediksi benar tambahan atau 6,00 poin persentase. Dibandingkan baseline tanpa MLP, S3, S8 menghasilkan 13 prediksi benar tambahan atau 5,20 poin persentase. Lima skenario (S2, S4, S5, S6, dan S8) melampaui target 90%, sebagaimana divisualisasikan pada Gambar 5. Pemisahan kedua baseline ini menghindari penggabungan pengaruh perubahan kepala dan augmentasi dalam satu klaim.

Tabel 4 Jumlah prediksi benar dan perubahan accuracy terhadap dua baseline

Skenario	Accuracy (%)	Benar / 250	Δ S1 (poin %)	Δ S3 (poin %)
S1	88,40	221	0,00	-0,80
S2	90,80	227	+2,40	+1,60
S3	89,20	223	+0,80	0,00
S4	92,40	231	+4,00	+3,20
S5	91,20	228	+2,80	+2,00
S6	90,40	226	+2,00	+1,20
S7	89,60	224	+1,20	+0,40
S8	94,40	236	+6,00	+5,20

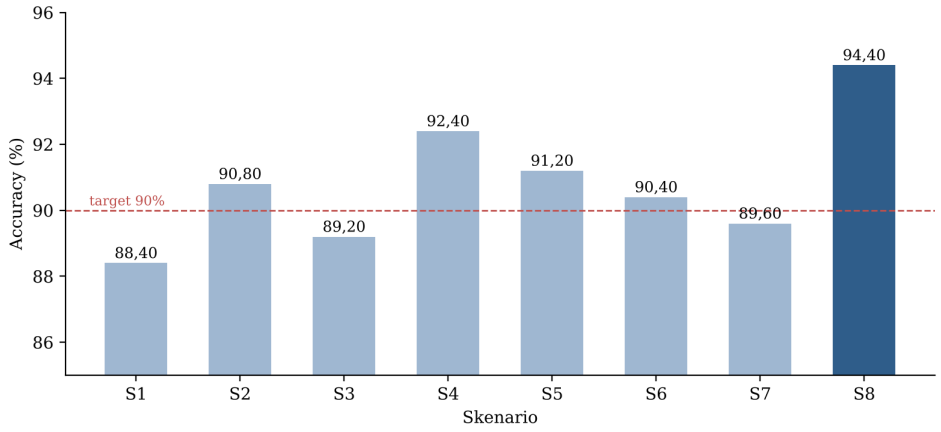

Gambar 5 Perbandingan akurasi delapan skenario eksperimen terhadap target capaian 90%

S8 merupakan konfigurasi dengan accuracy tertinggi di antara delapan skenario. Tabel 5 merinci kinerja per kelas. F1-score tertinggi diperoleh Normal (95,89%), sedangkan terendah Bacterial Leaf Blight (92,31%). Recall Bacterial Leaf Blight sebesar 90,00% berarti 18 dari 20 citra kelas tersebut dikenali dengan benar. Jumlah uji kelas ini paling kecil, sehingga satu kesalahan mengubah recall sebesar 5,00 poin persentase. Interpretasi kinerja kelas minoritas perlu mempertimbangkan ukuran sampel tersebut.

Tabel 5 Kinerja klasifikasi setiap kelas pada model terbaik S8

Kelas	Precision (%)	Recall (%)	F1-Score (%)
Bacterial Leaf Blight	94,74	90,00	92,31
Tungro	93,62	97,78	95,65
Normal	95,89	95,89	95,89
Brown Spot	97,37	92,50	94,87
Blast	91,78	93,06	92,41
Macro Average	94,68	93,84	94,23

Confusion matrix S8 pada Tabel 6 dan Gambar 6 memuat 236 prediksi benar dan 14 kesalahan. Baris menunjukkan kelas aktual dan kolom menunjukkan kelas prediksi. Blast memiliki lima citra yang salah diprediksi: satu sebagai Bacterial Leaf Blight, dua sebagai Tungro, satu sebagai Normal, dan satu sebagai Brown Spot. Sebaliknya, enam citra dari kelas lain diprediksi sebagai Blast, masing-masing dua dari Bacterial Leaf Blight, Normal, dan Brown Spot. Pola ini menunjukkan sumber kesalahan yang perlu diperiksa lebih lanjut; confusion matrix saja belum menjelaskan penyebab visual atau biologis setiap kesalahan. Nilai agregat S8 dihitung kembali dari matriks ini dan konsisten dengan Tabel 3 serta Tabel 5 setelah pembulatan dua desimal.

Tabel 6 Confusion matrix model terbaik S8 pada data uji (n = 250)

Aktual \ Prediksi	BLB	Tungro	Normal	Brown Spot	Blast
Bacterial Leaf Blight	18	0	0	0	2
Tungro	0	44	1	0	0
Normal	0	1	70	0	2
Brown Spot	0	0	1	37	2
Blast	1	2	1	1	67

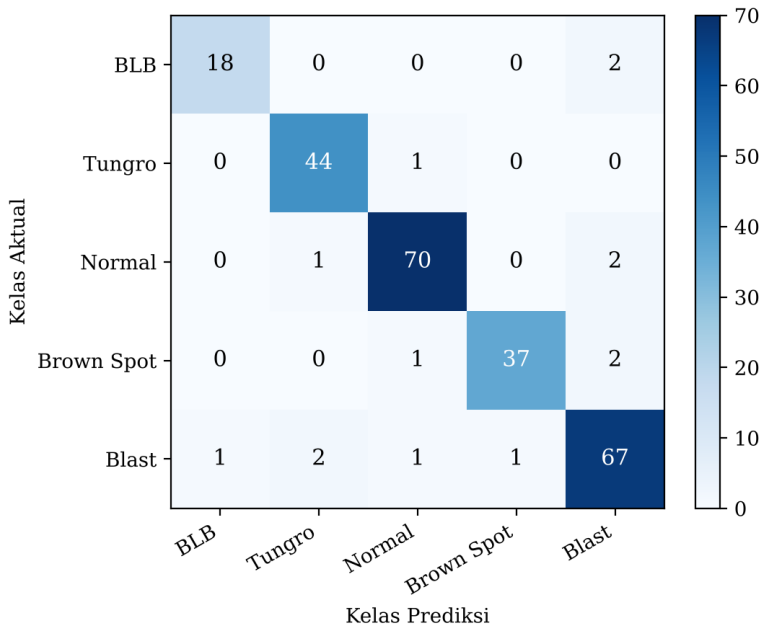

Gambar 6 Visualisasi confusion matrix model terbaik S8

Penghapusan lapisan dense antara mengurangi ukuran kepala klasifikasi secara teoritis. Untuk fitur GAP berdimensi 2.048 pada ResNet50 (He dkk., 2016), jumlah parameter lapisan dense dengan bias dihitung sebagai (m + 1)n, dengan m dimensi masukan dan n jumlah unit keluaran. Tabel 7 menunjukkan 2.755.589 parameter pada kepala dengan MLP dan 10.245 pada kepala tanpa MLP. Perhitungan ini hanya mencakup kepala yang dijelaskan dalam metode, bukan parameter backbone atau jumlah parameter yang benar-benar dilatih. Penurunan parameter kepala tidak otomatis membuktikan waktu inferensi lebih cepat atau overfitting lebih rendah; keduanya memerlukan pengukuran tersendiri.

Tabel 7 Jumlah parameter teoritis kepala klasifikasi dengan bias

Konfigurasi	Susunan lapisan dense	Parameter kepala
Dengan MLP	2048→1024→512→256→5	2.755.589
Tanpa MLP	2048→5	10.245

Catatan: perhitungan analitis untuk kepala setelah GAP, dengan 2.048 fitur masukan dan satu bias per unit dense. Tidak mencakup backbone, runtime, atau pengukuran memori.

Random Zoom memberikan kenaikan tertinggi di antara augmentasi tunggal pada kepala tanpa MLP: S4 mencapai 92,40%, meningkat 3,20 poin persentase dari S3. Random Brightness, Horizontal Flip, dan Vertical Flip masing-masing meningkat 2,00; 1,20; dan 0,40 poin persentase. Pada kepala dengan MLP, penerapan zoom meningkatkan accuracy dari 88,40% (S1) menjadi 90,80% (S2). Dengan demikian, arah perubahan terkait zoom sama pada kedua kepala yang diuji. Kombinasi pada S8 memberikan accuracy tertinggi, tetapi rancangan ini belum memisahkan kontribusi masing-masing transformasi dalam kombinasi. Keragaman geometris dan fotometrik dapat mendukung pembelajaran representasi (Shorten & Khoshgoftaar, 2019; Bari dkk., 2021), sementara ketangguhan lapangan tetap memerlukan validasi eksternal.

Hasil S8 memberikan dasar perbandingan internal pada subset lima kelas. Angka ini tidak digunakan untuk menyatakan keunggulan langsung terhadap PaddyNet yang dievaluasi pada 13 kelas atau model lain dengan protokol berbeda (Deng dkk., 2021; Dogra dkk., 2023; Petchiammal, Murugan, dkk., 2023; Ritharson dkk., 2024). Kontribusi penelitian terletak pada pengujian dua kepala klasifikasi untuk baseline dan zoom, serta pengujian augmentasi tunggal dan gabungan pada kepala tanpa MLP. Kesimpulan mengenai interaksi penuh antarfaktor membutuhkan rancangan faktorial yang lebih lengkap.

Keterbatasan penelitian

Penelitian ini menggunakan satu sumber data dan belum menguji citra lapangan eksternal. Rancangan delapan skenario bukan faktorial lengkap, dan hasil belum disertai pengulangan antar-seed atau estimasi ketidakpastian. Proporsi latih–validasi, seed pemisahan, audit duplikasi, inisialisasi bobot, status fine-tuning, optimizer, learning rate, batch size, epoch, loss, early stopping, formula normalisasi, versi framework, dan spesifikasi perangkat belum terdokumentasi secara lengkap. Detail implementasi augmentasi juga membatasi replikasi. Karena kebocoran data dapat menghasilkan estimasi kinerja yang terlalu optimistis (Kapoor & Narayanan, 2023), pemisahan terstratifikasi saja belum cukup untuk memastikan independensi seluruh citra. Temuan dibatasi pada perbandingan deskriptif, tanpa klaim signifikansi statistik, keunggulan diagnosis lapangan, atau efisiensi inferensi yang sudah terukur.

KESIMPULAN

Pada subset lima kelas dan 250 citra uji, penghapusan lapisan dense antara pada kepala ResNet50 menaikkan accuracy dasar dari 88,40% menjadi 89,20%. Random Zoom memberikan accuracy tertinggi di antara augmentasi tunggal pada kepala tanpa MLP, yaitu 92,40%. Konfigurasi S8 dengan gabungan empat augmentasi mencapai accuracy 94,40%, macro-precision 94,68%, macro-recall 93,84%, dan macro-F1 94,23%. Kenaikannya sebesar 6,00 poin persentase terhadap S1 dan 5,20 poin persentase terhadap S3. Pengurangan lapisan juga menurunkan jumlah parameter kepala secara teoritis, tetapi

efisiensi waktu dan generalisasi lapangan belum terukur. Hasil ini mendukung pemilihan S8 sebagai konfigurasi terbaik dalam eksperimen ini, dengan batas pada dataset dan protokol evaluasi yang digunakan.

Penelitian berikutnya perlu mendokumentasikan pembagian data dan konfigurasi pelatihan secara lengkap, mengulang pelatihan dengan beberapa seed, serta memeriksa duplikasi atau keterkaitan objek antarsubset. Evaluasi pada citra sawah lokal di wilayah Cirebon, pengukuran waktu inferensi dan memori, serta pengujian penyeimbangan kelas dapat menjadi dasar pengembangan purwarupa aplikasi deteksi dini.

UCAPAN TERIMA KASIH

Penelitian ini didanai oleh hibah Penelitian Dosen Institut Teknologi dan Kesehatan Mahardika tahun pelaksanaan 2023/2024. Penulis mengucapkan terima kasih yang sebesar-besarnya kepada Lembaga Penelitian dan Pengabdian kepada Masyarakat (LPPM) ITEKes Mahardika atas dukungan pendanaan dan fasilitas yang diberikan selama pelaksanaan penelitian ini, serta kepada pimpinan Program Studi Informatika atas penyediaan sarana komputasi laboratorium.

KONTRIBUSI PENULIS

Para penulis menyatakan kontribusi mereka terhadap penelitian/manuskrip ini dalam format CRediT (Contributor Roles Taxonomy) sebagai berikut. Mohamad Firdaus, M.Kom.: Conceptualization, Methodology, Software, Formal Analysis, Supervision, Project Administration, dan Writing - Original Draft; Ari Fiandi: Data Curation, Resources, dan Investigation; Indah Rizkika: Software, Validation, dan Investigation; serta Dimas Dwi Rianto: Formal Analysis, Investigation, Project Administration, dan Writing - Review & Editing. Semua penulis telah membaca dan menyetujui versi akhir dari naskah ini.

PERNYATAAN KETERSEDIAAN DATA

Dataset sumber tersedia melalui halaman kompetisi Paddy Doctor: Paddy Disease Classification di Kaggle: https://www.kaggle.com/competitions/paddy-disease-classification/data. Akses dan penggunaan mengikuti ketentuan kompetisi. Penelitian ini menggunakan subset lima kelas berjumlah 6.034 citra sebagaimana dirinci pada Tabel 2. Daftar ID citra per subset, kode pelatihan, dan bobot model tersedia dari para penulis atas permintaan yang wajar.

PERNYATAAN BEBAS KONFLIK KEPENTINGAN

Para penulis menyatakan bahwa tidak ada konflik kepentingan finansial maupun hubungan pribadi yang dapat mempengaruhi hasil yang dilaporkan dalam naskah ini.

PERNYATAAN ETIKA PENELITIAN DAN PUBLIKASI

Para penulis menyatakan bahwa penelitian dan penulisan naskah ini telah mematuhi standar etika penelitian dan publikasi, sesuai dengan prinsip ilmiah, serta bebas dari plagiasi.

PERNYATAAN PEMANFAATAN TEKNOLOGI ASISTIF

Teknologi AI generatif dan teknologi asistif digunakan untuk membantu penyuntingan bahasa, penelusuran referensi, penataan naskah, dan pemeriksaan konsistensi penyajian. Penggunaannya tidak menggantikan data eksperimen atau pelaksanaan penelitian. Para penulis bertanggung jawab atas keakuratan data, interpretasi hasil, serta pemeriksaan dan persetujuan naskah akhir.

REFERENSI

Ahad, M. T., Li, Y., Song, B., & Bhuiyan, T. (2023). Comparison of CNN-based deep learning architectures for rice diseases classification. *Artificial Intelligence in Agriculture*, 9, 22–35. https://doi.org/10.1016/j.aiia.2023.07.001

Bari, B. S., Islam, M. N., Rashid, M., Hasan, M. J., Razman, M. A. M., Musa, R. M., Ab Nasir, A. F., & Abdul Majeed, A. P. P. (2021). A real-time approach of diagnosing rice leaf disease using deep learning-based faster R-CNN framework. *PeerJ Computer Science*, 7, Article e432. https://doi.org/10.7717/peerj-cs.432

Cui, J., & Tan, F. (2023). Rice plaque detection and identification based on an improved convolutional neural network. *Agriculture*, 13(1), Article 170. https://doi.org/10.3390/agriculture13010170

Deng, R., Tao, M., Xing, H., Yang, X., Liu, C., Liao, K., & Qi, L. (2021). Automatic diagnosis of rice diseases using deep learning. *Frontiers in Plant Science*, 12, Article 701038. https://doi.org/10.3389/fpls.2021.701038

Dixit, A. K., & Verma, R. (2023). Advanced hybrid model for multi paddy diseases detection using deep learning. *EAI Endorsed Transactions on Pervasive Health and Technology*, 9(1), 1–8. https://doi.org/10.4108/eetpht.9.4481

Dogra, R., Rani, S., Singh, A., Albahar, M. A., Barrera, A. E., & Alkhayyat, A. (2023). Deep learning model for detection of brown spot rice leaf disease with smart agriculture. *Computers and Electrical Engineering*, 109, Article 108659. https://doi.org/10.1016/j.compeleceng.2023.108659

Fukagawa, N. K., & Ziska, L. H. (2019). Rice: Importance for global nutrition. *Journal of Nutritional Science and Vitaminology*, 65(Supplement), S2–S3. https://doi.org/10.3177/jnsv.65.S2

Goluguri, N. V. R. R., Suganya Devi, K., & Vadaparthi, N. (2021). Image classifiers and image deep learning classifiers evolved in detection of Oryza sativa diseases: Survey. *Artificial Intelligence Review*, 54(1), 359–396. https://doi.org/10.1007/s10462-020-09849-y

Gupta, T., Titunath, & Jain, V. (2023). Plant disease detection using deep learning. In *2023 International Conference on Sustainable Computing and Smart Systems (ICSCSS)* (pp. 202–206). IEEE. https://doi.org/10.1109/ICSCSS57650.2023.10169268

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 770–778). IEEE. https://doi.org/10.1109/CVPR.2016.90

Jesie, R. S., Godwin Premi, M. S., & Jarin, T. (2024). Comparative analysis of paddy leaf diseases sensing with a hybrid convolutional neural network model. *Measurement: Sensors*, 31, Article 100966. https://doi.org/10.1016/j.measen.2023.100966

Jiang, F., Lu, Y., Chen, Y., Cai, D., & Li, G. (2020). Image recognition of four rice leaf diseases based on deep learning and support vector machine. *Computers and Electronics in Agriculture*, 179, Article 105824. https://doi.org/10.1016/j.compag.2020.105824

Kapoor, S., & Narayanan, A. (2023). Leakage and the reproducibility crisis in machine-learning-based science. *Patterns*, 4(9), Article 100804. https://doi.org/10.1016/j.patter.2023.100804

Khan, A. R., Abunadi, I., Alghofaily, B., Ali, H., & Saba, T. (2023). Automatic diagnosis of rice leaves diseases using hybrid deep learning model. *Journal of Advances in Information Technology*, 14(3), 418–425. https://doi.org/10.12720/jait.14.3.418-425

Latif, G., Abdelhamid, S. E., Mallouhy, R. E., Alghazo, J., & Kazimi, Z. A. (2022). Deep learning utilization in agriculture: Detection of rice plant diseases using an improved CNN model. *Plants*, 11(17), Article 2230. https://doi.org/10.3390/plants11172230

Liu, H., Cui, Y., Wang, J., & Yu, H. (2023). Analysis and research on rice disease identification method based on deep learning. *Sustainability*, 15(12), Article 9321. https://doi.org/10.3390/su15129321

Lu, Y., Wu, X., Liu, P., Li, H., & Liu, W. (2023). Rice disease identification method based on improved CNN-BiGRU. *Artificial Intelligence in Agriculture*, 9, 100–109. https://doi.org/10.1016/j.aiia.2023.08.005

Lu, Y., Yi, S., Zeng, N., Liu, Y., & Zhang, Y. (2017). Identification of rice diseases using deep convolutional neural networks. *Neurocomputing*, 267, 378–384. https://doi.org/10.1016/j.neucom.2017.06.023

Paddy Doctor. (2022). *Paddy Doctor: Paddy disease classification* [Data set]. Kaggle. https://www.kaggle.com/competitions/paddy-disease-classification/data

Petchiammal, A., Briskline Kiruba, S., Murugan, D., & Pandarasamy, A. (2023). Paddy Doctor: A visual image dataset for automated paddy disease classification and benchmarking. In *Proceedings of the 6th Joint International Conference on Data Science & Management of Data (CODS-COMAD)* (pp. 203–207). ACM. https://doi.org/10.1145/3570991.3570994

Petchiammal, A., Murugan, D., & Briskline Kiruba, S. (2023). PaddyNet: An improved deep convolutional neural network for automated disease identification on visual paddy leaf images. *International Journal of Advanced Computer Science and Applications*, 14(6), 1141–1149. https://doi.org/10.14569/IJACSA.2023.01406122

Prathima, S., Praveena, N. G., Sivachandar, K., Nath, S. S., & Sarala, B. (2023). Generic Paddy Plant Disease Detector (GP2D2): An application of the Deep-CNN model. *International Journal of Electrical and Computer Engineering Systems*, 14(6), 647–656. https://doi.org/10.32985/IJECES.14.6.4

Rahman, C. R., Arko, P. S., Ali, M. E., Iqbal Khan, M. A., Apon, S. H., Nowrin, F., & Wasif, A. (2020). Identification and recognition of rice diseases and pests using convolutional neural networks. *Biosystems Engineering*, 194, 112–120. https://doi.org/10.1016/j.biosystemseng.2020.03.020

Ritharson, P. I., Raimond, K., Mary, X. A., Robert, J. E., & J, A. (2024). DeepRice: A deep learning and deep feature based classification of rice leaf disease subtypes. *Artificial Intelligence in Agriculture*, 11, 34–49. https://doi.org/10.1016/j.aiia.2023.11.001

Senthil Pandi, S., Senthilselvi, A., Gitanjali, J., ArivuSelvan, K., Gopal, J., & Vellingiri, J. (2022). Rice plant disease classification using dilated convolutional neural network with global average pooling. *Ecological Modelling*, 474, Article 110166. https://doi.org/10.1016/j.ecolmodel.2022.110166

Sethy, P. K., Barpanda, N. K., Rath, A. K., & Behera, S. K. (2020). Deep feature based rice leaf disease identification using support vector machine. *Computers and Electronics in Agriculture*, 175, Article 105527. https://doi.org/10.1016/j.compag.2020.105527

Shah, J. P., Prajapati, H. B., & Dabhi, V. K. (2016). A survey on detection and classification of rice plant diseases. In *2016 IEEE International Conference on Current Trends in Advanced Computing (ICCTAC)* (pp. 1–8). IEEE. https://doi.org/10.1109/ICCTAC.2016.7567333

Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), Article 60. https://doi.org/10.1186/s40537-019-0197-0

Simhadri, C. G., & Kondaveeti, H. K. (2023). Automatic recognition of rice leaf diseases using transfer learning. *Agronomy*, 13(4), Article 961. https://doi.org/10.3390/agronomy13040961

Zhang, C., Ni, R., Mu, Y., Sun, Y., & Tyasi, T. L. (2023). Lightweight multi-scale convolutional neural network for rice leaf disease recognition. *Computers, Materials & Continua*, 74(1), 983–994. https://doi.org/10.32604/cmc.2023.027269