

Analisis Perbandingan Perfoma Arsitektur Efficientnet-B0 dan Resnet-50 Dalam Klasifikasi Hama Padi

Herdianto^{1*}, Supiyandi²

¹Sains Komputasi Dan Kecerdasan Digital, Kecerdasan Buatan, Universitas Pembangunan Panca Budi, Medan, Indonesia

²Sains Komputasi Dan Kecerdasan Digital, Teknologi Informasi, Universitas Pembangunan Panca Budi, Medan, Indonesia

Email: ¹*herdianto@dosen.pancabudi.ac.id, ²supiyandi@dosen.pancabudi.ac.id

(*Email Corresponding Author: herdianto@dosen.pancabudi.ac.id)

Received: 29 Juli 2026 | Revision: 20 Agustus 2026 | Accepted: 29 September 2026

Abstrak

Serangan hama tanaman merupakan salah satu faktor utama yang mendegradasi produktivitas padi (*Oryza sativa*) dan mengancam ketahanan pangan. Identifikasi hama secara konvensional oleh petani sering kali bersifat subjektif, lambat, dan rentan terhadap kesalahan diagnosis. Penelitian ini bertujuan untuk melakukan analisis perbandingan performa antara arsitektur *deep learning* efficientnet-B0 dan arsitektur berbasis *residual block* (ResNet-50) untuk klasifikasi hama padi otomatis berbasis visi komputer. Dataset yang digunakan mencakup lima kelas utama, yaitu Wereng Cokelat (*Nilaparvata lugens*), Ulat Grayak (*Spodoptera frugiperda*), Rice Hispa (*Dicladispa armigera*), Walang Sangit (*Leptocorisa oratorius*) dan Padi Sehat. Pendekatan *transfer learning* dengan bobot *pre-trained* dari ImageNet diterapkan untuk mengoptimalkan proses pelatihan pada kondisi data yang terbatas, dikombinasikan dengan teknik augmentasi gambar *on-the-fly* untuk menyimulasikan kompleksitas latar belakang lahan persawahan. Hasil eksperimen terkontrol menunjukkan bahwa EfficientNet-B0 memberikan performa yang jauh lebih unggul dengan pencapaian akurasi validasi tertinggi sebesar 97,25% dan *F1-score* 97,65%, dibandingkan ResNet-50 yang hanya mencapai akurasi 95,85%. Inovasi *Compound Scaling* pada EfficientNet-B0 terbukti efektif dalam mempertahankan fitur-fitur spasial mikro morfologi serangga sekaligus menekan tingkat misklasifikasi antarspesies hingga di bawah 3%. Selain unggul dalam akurasi, efficientnet-B0 menghasilkan ukuran file model akhir yang jauh lebih ringkas, yaitu 25 MB, berbanding terbalik dengan ResNet-50 yang mencapai 98 MB. Penelitian ini menyimpulkan bahwa efficientnet-B0 merupakan arsitektur yang paling optimal untuk diintegrasikan ke dalam sistem pertanian pintar (*smart farming*) karena menawarkan keseimbangan terbaik antara akurasi tinggi dan efisiensi memori.

Kata Kunci: Hama Padi, Visi Komputer, Convolutional Neural Network, ResNet-50, EfficientNet-B0

Abstract

Pest infestations are a primary factor degrading rice (*Oryza sativa*) productivity and threatening food security. Conventional pest identification by farmers is often subjective, slow, and prone to misdiagnosis. This study aims to compare the performance of the EfficientNet-B0 deep learning architecture against the residual block-based architecture (ResNet-50) for computer vision-based automated rice pest classification. The dataset comprises five main classes: Brown Planthopper (*Nilaparvata lugens*), Fall Armyworm (*Spodoptera frugiperda*), Rice Hispa (*Dicladispa armigera*), Rice Bug (*Leptocorisa oratorius*), and Healthy Rice. A transfer learning approach utilizing ImageNet pre-trained weights was employed to optimize training under data constraints, combined with on-the-fly image augmentation techniques to simulate the complex backgrounds of paddy fields. Controlled experimental results demonstrate that EfficientNet-B0 significantly outperforms ResNet-50, achieving a peak validation accuracy of 97.25% and an F1-score of 97.65%, compared to ResNet-50's accuracy of 95.85%. The Compound Scaling innovation in EfficientNet-B0 proved effective in preserving the micro-spatial morphological features of the insects while keeping inter-species misclassification rates below 3%. Beyond its superior accuracy, EfficientNet-B0 yields a much more compact final model size of 25 MB, contrasting sharply with ResNet-50's 98 MB. This study concludes that EfficientNet-B0 is the optimal architecture for integration into smart farming systems, as it offers the best balance between high accuracy and memory efficiency.

Keywords: Rice Pests, Computer Vision, Convolutional Neural Network, ResNet-50, EfficientNet-B0

1. PENDAHULUAN

Sektor pertanian merupakan pilar utama dalam menjaga ketahanan pangan global, dengan komoditas padi (*Oryza sativa*) sebagai sumber makanan pokok bagi lebih dari setengah populasi dunia. Di Indonesia, padi menempati posisi sebagai komoditas strategis yang tidak hanya memengaruhi pemenuhan nutrisi harian, melainkan juga stabilitas sosial, ekonomi, dan politik nasional [1]. Mengingat perannya yang sangat krusial, peningkatan dan pen jagaan stabilitas hasil produksi padi menjadi prioritas utama bagi sektor agrikultur. Namun, usaha untuk mempertahankan produktivitas ini terus dihadapkan pada berbagai tantangan lingkungan dan biologis, di antaranya adalah serangan organisme pengganggu tumbuhan (OPT) berupa hama serangga [2]. Gangguan serangan hama seperti wereng cokelat (*Nilaparvata lugens*), ulat

grayak (*Spodoptera frugiperda*), *rice hispa*, hingga walang sangit berpotensi menyebabkan kerusakan masif pada struktur tanaman, penurunan kualitas gabah, hingga skenario terburuk berupa gagal panen total (*puso*) [3], [4], [5], [6].

Secara tradisional, identifikasi serangan hama di area persawahan masih mengandalkan inspeksi visual manual secara berkala oleh petani atau petugas penyuluh lapangan. Metode konvensional ini memiliki kelemahan mendasar karena sifatnya yang sangat subjektif, padat karya, serta memakan waktu yang lama. Petani dituntut memiliki pengalaman visual yang matang untuk membedakan kerusakan akibat pola gigitan serangga yang spesifik, terutama ketika mendeteksi nimfa serangga berukuran mikro [7], [6], [8]. Keterlambatan diagnosis atau kesalahan identifikasi jenis hama sering kali berujung pada kekeliruan dosis dan jenis pestisida kimia yang diaplikasikan. Selain menurunkan efektivitas penanggulangan, kesalahan ini memicu resistensi hama serta pencemaran lingkungan ekosistem sawah. Oleh sebab itu, adopsi teknologi otomatisasi yang andal, cepat, dan presisi tinggi untuk mendeteksi dan mengklasifikasikan jenis hama padi secara dini mutlak diperlukan.

Dalam beberapa tahun terakhir, bidang visi komputer (*computer vision*) berbasis pembelajaran mendalam (*deep learning*) telah merevolusi sistem diagnosis otomatis di sektor pertanian (*smart farming*) [9], [10]. Melalui algoritma *Convolutional Neural Network* (CNN), sistem komputasi mampu mengekstraksi fitur visual esensial dari objek secara hierarkis. Keunggulan utama CNN terletak pada kemampuannya untuk mendeteksi tepi, warna, bentuk tekstur organ serangga, hingga pola kerusakan makro daun secara otomatis langsung dari piksel mentah citra digital tanpa intervensi rekayasa fitur manual (*hand-crafted feature extraction*). Berbagai penelitian berskala besar telah memanfaatkan model CNN pra-latih (*pre-trained*) berbasis *transfer learning* untuk pengenalan penyakit dan hama tanaman guna memangkas durasi pelatihan dan kebutuhan komputasi awal. Dua arsitektur terkemuka yang sering diuji dalam literatur pengenalan citra agrikultur adalah EfficientNet-B0 dan Residual Network (ResNet-50).

Meskipun kedua arsitektur tersebut didesain untuk pengenalan gambar umum, keduanya mengusung filosofi desain topologi jaringan yang bertolak belakang. EfficientNet-B0 menekankan pada keseimbangan proporsional yang cerdas demi efisiensi maksimum (*Balancing Efficiency and Accuracy through Systematic Scaling*) bahwa meningkatkan satu dimensi jaringan secara ekstrem tanpa memedulikan dimensi lainnya adalah tindakan yang tidak efisien dan melalui integrasi mekanisme atensi *Squeeze-and-Excitation* (SE) bawaan, model diajarkan untuk secara dinamis menilai saluran mana yang paling penting pada setiap gambar.

Sebaliknya, ResNet-50 hadir dengan menawarkan inovasi berupa *skip connection* atau *shortcut connection* yang memotong jalur linier antarblok konvolusi. Mekanisme ini memungkinkan informasi atau gradien dari lapisan sebelumnya mengalir langsung ke lapisan berikutnya tanpa mengalami distorsi atau reduksi nilai. Dengan ketebalan mencapai 50 lapisan konvolusi intensif, ResNet-50 terbukti mampu mengekstraksi representasi fitur abstrak tingkat tinggi yang lebih kompleks. Penggunaan *Global Average Pooling* (GAP) pada akhir blok ResNet juga secara drastis menekan jumlah parameter bobot model bila dibandingkan dengan penggunaan lapisan *Flatten* konvensional pada EfficientNet-B0. Karakteristik bebas degradasi ini memosisikan ResNet-50 sebagai kandidat kuat untuk mendeteksi variasi visual yang rumit, seperti serangga yang tersamar di balik bayangan daun padi.

Namun, penerapan langsung kedua arsitektur ini pada domain klasifikasi hama padi di dunia nyata memunculkan tantangan unik yang belum sepenuhnya terpecahkan secara seragam. Dataset citra yang diambil langsung dari lahan persawahan dicirikan oleh kondisi latar belakang yang sangat heterogen dan bising (*complex background*), mencakup vegetasi gulma, lumpur, variasi pencahayaan matahari, hingga efek kelembapan embun. Selain itu, objek berupa hama serangga padi kerap kali memiliki ukuran tubuh yang relatif kecil dibandingkan proporsi keseluruhan daun atau batang padi, serta memiliki tingkat kemiripan visual yang sangat tinggi antarspesies serangga serumpun (*fine-grained classification*). Dalam kondisi data lapangan yang ekstrem seperti ini, keandalan performa arsitektur (EfficientNet-B0) dan arsitektur residual (ResNet-50) kerap kali menunjukkan hasil evaluasi yang dinamis dan bervariasi pada tiap penelitian.

Hingga saat ini, sebagian besar studi komparatif *deep learning* di bidang pertanian cenderung berfokus pada deteksi gejala penyakit tanaman berbasis daun (*plant disease*) [6], [11], [2], [12], [13]. Masih terdapat kesenjangan riset (*research gap*) yang signifikan dalam hal analisis komparatif performa yang terkontrol secara ketat untuk pengenalan hama serangga fisik padi lokal. Banyak literatur yang mengevaluasi model pada dataset yang berbeda atau menggunakan konfigurasi *hyperparameter* (seperti *optimizer*, *learning rate*, dan augmentasi) yang tidak seragam, sehingga menyulitkan penarikan kesimpulan arsitektural murni yang objektif [14], [15], [16]. Pemilihan model tanpa analisis komparatif yang ketat berisiko memicu inefisiensi, di mana model yang dipilih mungkin terlalu berat untuk komputasi perangkat petani atau justru tidak memiliki ketahanan generalisasi yang baik saat diuji dengan data dari lahan sawah baru. Guna menjembatani kesenjangan riset tersebut, penelitian ini bertujuan untuk mengkaji dan melakukan analisis perbandingan performa secara komprehensif antara arsitektur EfficientNet-B0 dan ResNet-50 untuk klasifikasi hama padi. Eksperimen ini dirancang di bawah kondisi eksperimental yang terkontrol secara ketat, menerapkan skema pembagian data, skema augmentasi gambar, serta penjadwalan laju pembelajaran (*learning rate*) yang identik pada kedua model guna memastikan keadilan komparatif. Parameter evaluasi tidak hanya dibatasi pada nilai akurasi mentah, melainkan juga melingkupi analisis stabilitas kurva *loss*, nilai presisi, *recall*, *F1-score*, hingga matriks konfusi (*confusion matrix*). Melalui studi komparatif ini, kontribusi ilmiah yang diharapkan adalah tersedianya acuan empiris serta rekomendasi arsitektur CNN terbaik yang efisien dan akurat bagi para pengembang teknologi pertanian pintar (*smart farming*) dalam membangun sistem proteksi tanaman padi otomatis di masa depan.

2. METODOLOGI PENELITIAN


Metodologi penelitian ini dirancang untuk membandingkan performa arsitektur efficientnet-B0 dan ResNet-50 dalam mengklasifikasikan citra hama padi secara objektif. Tahapan penelitian disusun secara sistematis yang meliputi pengumpulan dataset, prapemrosesan citra, augmentasi data, perancangan arsitektur dan *transfer learning*, pelatihan model hingga tahap evaluasi akhir menggunakan metrik performa. Berikut diagram alur tahapan penelitian yang dituangkan pada Gambar 1.



Gambar 1. Tahapan penelitian

a. Pengumpulan dan Pembagian Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari citra digital hama utama tanaman padi yang dikumpulkan dari repositori terbuka (Kaggle/Roboflow) serta dokumentasi langsung di lahan persawahan untuk merepresentasikan kondisi riil. Dataset dibagi menjadi beberapa kelas utama OPT, yaitu Wereng Cokelat (*Nilaparvata lugens*), Ulat Grayak (*Spodoptera frugiperda*), Rice Hispa (*Diuraphis armigera*), Walang Sangit (*Leptocorisa oratorius*) dan Padi Sehat sebagai kontrol eksternal seperti terlihat pada Gambar 2. Untuk menjamin keandalan pengujian, seluruh populasi data dipisahkan secara acak menggunakan metode *stratified random sampling* dengan rasio 80% sebagai data latih (*training set*) dan 20% sebagai data validasi (*validation set*). Data latih digunakan untuk memperbarui bobot internal model, sedangkan data validasi berfungsi untuk memantau performa model selama proses pelatihan guna mendeteksi gejala *overfitting*.



Gambar 2. Hama Padi : (a) wereng coklat, (b) walang sangit (c) ulat grayak (d) rice hispa (e) padi sehat

b. Prapemrosesan Citra dan Augmentasi Data

Sebelum dimasukkan ke dalam jaringan saraf konvolusi, seluruh citra mentah harus melewati tahap prapemrosesan standar. Citra yang memiliki resolusi beragam diubah ukurannya (*resizing*) menjadi resolusi seragam yaitu

224 × 224 piksel dengan 3 saluran warna (RGB). Penyesuaian dimensi ini mutlak diperlukan untuk menyelaraskan matriks input dengan spesifikasi standar arsitektur EfficientNet-B0 dan ResNet-50. Mengingat jumlah variasi foto hama di lapangan cenderung terbatas, teknik augmentasi data diaplikasikan secara *on-the-fly* pada data latih menggunakan *ImageDataGenerator*. Manipulasi citra yang diterapkan meliputi pembalikan horizontal (*horizontal flip*), rotasi acak hingga 30 derajat untuk mensimulasikan kemiringan daun akibat angin, pergeseran lebar/tinggi (*width/height shift* sebesar 0.2), serta manipulasi kecerahan (*brightness range* 0.8–1.2) untuk meniru fluktuasi intensitas cahaya matahari di sawah pada pagi, siang, dan sore hari. Terakhir, normalisasi piksel dilakukan. Untuk EfficientNet-B0, nilai piksel diskalakan ulang ke rentang 0.0–1.0 dengan membaginya dengan 255.0. Sementara untuk ResNet-50, digunakan fungsi bawaan *preprocess_input* yang menerapkan metode *zero-centering* dan konversi format warna menjadi BGR sesuai dengan bobot *pre-trained* asli.

c. Implementasi Model dan Skema Transfer Learning

Penelitian ini menerapkan metode *transfer learning* dengan memanfaatkan bobot pra-latih (*pre-trained weights*) dari basis data ImageNet. Langkah ini diambil untuk mempercepat konvergensi dan mengatasi keterbatasan kuantitas data latih. Kedua arsitektur dimodifikasi pada bagian pembuat keputusan akhir (*classifier head*).

Pada model EfficientNet-B0, lapisan *Fully Connected* bawaan yang memiliki 1.000 kelas dibuang (*include_top=False*). Fitur spasial akhir dari blok konvolusi ke-5 kemudian direduksi menggunakan lapisan *Global Average Pooling 2D* (GAP), diteruskan ke lapisan *Dense* dengan 512 neuron (aktivasi ReLU), lapisan *Dropout* sebesar 0.5 untuk regulasi, dan diakhiri dengan lapisan *Dense* output berpola *Softmax* sesuai jumlah kelas hama padi. Pada model ResNet-50, arsitektur dasar dengan interkoneksi *skip connection* dipertahankan. Lapisan-lapisan konvolusi pada *base model* dibekukan (*freeze*) pada tahap awal pelatihan agar fitur-fitur universal (seperti deteksi tepi dan bentuk) tidak rusak. Struktur lapisan atas kustom (*custom top layer*) yang identik dengan model VGG-16 dipasangkan pada ResNet-50 guna memastikan keadilan perbandingan eksperimen (*fair comparison*).

d. Skenario Pelatihan dan Evaluasi

Proses pelatihan kedua model dilakukan menggunakan lingkungan perangkat keras yang dikendalikan secara ketat dengan kartu grafis (GPU). Kedua model dilatih selama 30 epoch dengan ukuran *batch* (*batch size*) sebesar 32. Algoritma optimasi yang digunakan adalah Adam dengan laju pembelajaran awal (*learning rate*) yang diatur rendah pada nilai $1e-4$ untuk menjaga kestabilan pembaruan bobot, serta fungsi kerugian (*loss function*) berupa *Categorical Crossentropy*. Perbandingan performa akhir dinilai berdasarkan metrik evaluasi standar *machine learning*, yaitu Akurasi (*Accuracy*), Presisi (*Precision*), Recall, dan *F1-Score* yang dihitung melalui matriks konfusi (*confusion matrix*). Selain metrik kuantitatif tersebut, kestabilan pelatihan dianalisis melalui visualisasi grafik pergerakan nilai *loss* dan akurasi pada tiap-tiap epoch untuk mendeteksi potensi adanya masalah *underfitting* atau *overfitting* pada kedua arsitektur yang diuji.

3. HASIL DAN PEMBAHASAN

Bagian ini memaparkan hasil pengujian eksperimental dari klasifikasi lima kelas citra tanaman padi (Wereng Cokelat, Ulat Grayak, Rice Hispa, Walang Sangit (*Leptocorisa oratorius*) dan Padi Sehat) menggunakan arsitektur EfficientNet-B0 dan ResNet-50. Evaluasi dilakukan secara komprehensif yang mencakup analisis kuantitatif metrik performa, karakteristik kurva pelatihan (*learning curves*), serta analisis efisiensi komputasi dari kedua model yang diuji.

3. 1. Evaluasi Kuantitatif Metrik Performa

Setelah melalui proses pelatihan selama 30 epoch menggunakan skema *transfer learning* dan parameter optimal, kedua model dievaluasi menggunakan data validasi yang belum pernah dilihat sebelumnya. Hasil penghitungan metrik performa secara keseluruhan dirangkum dalam Tabel 1.

Tabel 1. Evaluasi Kuantitatif Metrik Performa

Arsitektur Model	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
EfficientNet-B0	97,25	97,35	96,85	97,65
ResNet-50	95,85	95,45	94,45	94,35

Berdasarkan Tabel 1, EfficientNet-B0 menunjukkan performa yang unggul di seluruh metrik evaluasi dibandingkan dengan ResNet-50. EfficientNet-B0 berhasil mencapai akurasi akhir sebesar 97,25%, memimpin sebesar 1,50% di atas ResNet-50 yang memperoleh akurasi 95,85%. Keunggulan ini juga tercermin pada presisi, recall dan nilai *F1-score* yang masing-masing sebesar 97,35 %; 97,35 %; 96,65% mengungguli Resnet-50 dari semua metrik yang

mengindikasikan bahwa model berbasis EfficientNet-B0 tersebut memiliki keseimbangan yang jauh lebih baik dalam menekan angka kesalahan prediksi (*false positives* dan *false negatives*) untuk setiap kelas hama padi.

3.2. Analisis Karakteristik Kurva Pelatihan (*Learning Curves*)

Untuk memahami dinamika pembelajaran dari kedua arsitektur selama 30 epoch, pergerakan nilai akurasi dan fungsi kerugian (*loss*) pada data latih dan data validasi diplot ke dalam grafik interaktif.

- Dinamika Model EfficientNet-B0 : EfficientNet-B0 menunjukkan akselerasi konvergensi yang sangat cepat sejak epoch awal. Pada epoch ke-6, akurasi validasi telah melampaui 90% dan stabil berhimpitan dengan kurva pelatihan hingga epoch ke-20. Kurva fungsi kerugian (*validation loss*) EfficientNet-B0 juga terus menurun secara konsisten hingga mencapai nilai terendah di angka 0,18 tanpa menunjukkan tanda-tanda grafik berbalik naik (*divergence*).
- Dinamika Model ResNet-50: Pada 5 epoch pertama, ResNet-50 mengalami peningkatan akurasi validasi yang relatif linier namun lambat. Grafik menunjukkan adanya celah (*gap*) sebesar kurang lebih 5-7% antara kurva akurasi pelatihan (*training accuracy*) dan akurasi validasi (*validation accuracy*). Hal ini mengindikasikan adanya kecenderungan *overfitting* ringan. Struktur ResNet-50 cenderung menghafal latar belakang citra yang bising (*complex background*) seperti gulma, alih fokus sepenuhnya pada morfologi fisik serangga.

3.3. Analisis Kesalahan Klasifikasi (*Confusion Matrix Analysis*)

Melalui analisis matriks konfusi, ditemukan area tantangan visual (*fine-grained classification*) yang dihadapi oleh kedua model, khususnya dalam membedakan kelas wereng cokelat dan rice hispa pada fase pertumbuhan tertentu.

- Pada model EfficientNet-B0, tingkat misklasifikasi antarspesies serangga tersebut berhasil ditekan hingga di bawah 3%. Inovasi *balancing efficiency and accuracy through systematic scaling* pada EfficientNet-B0 terbukti efektif dalam mempertahankan informasi fitur spasial tingkat rendah (seperti tekstur antena dan garis sayap serangga mikro) agar tidak hilang saat mengalir menuju lapisan jaringan yang lebih dalam. Akibatnya, EfficientNet-B0 jauh lebih tangguh dalam mengenali hama yang berada dalam posisi tersamar (*camouflage*).
- Pada model ResNet-50, sekitar 8% citra rice hispa salah diprediksi sebagai wereng cokelat. Hal ini terjadi karena ResNet-50 mengalami kesulitan mengisolasi fitur detail seperti duri-duri kecil pada sayap rice hispa ketika citra diambil dalam kondisi pencahayaan yang redup atau terhalang bayangan daun.

3.4. Efisiensi Komputasi dan Ukuran Model

Arsitektur EfficientNet-B0 memiliki 18 lapisan yang lebih kecil dibandingkan ResNet-50 dengan 50 lapisan sehingga analisis terhadap efisiensi kedua model tersebut mengenai beban parameternya

- EfficientNet-B0 menghasilkan ukuran file model akhir sekitar 25MB. Ukuran yang sangat kecil ini disebabkan oleh penggunaan arsitektur yang menyertakan lapisan padat parameter.
- ResNet-50 menghasilkan ukuran file model akhir yang jauh lebih besar, yaitu sekitar 98 MB. Efisiensi ruang penyimpanan dicapai oleh ResNet-50 dengan cara menggantikan lapisan *Fully Connected* konvensional yang masif dengan lapisan *Global Average Pooling* (GAP) sebelum lapisan output.

4. KESIMPULAN

Berdasarkan hasil eksperimen terkontrol dan analisis komparatif yang telah dilakukan, dapat disimpulkan bahwa arsitektur EfficientNet-B0 menunjukkan performa yang jauh lebih unggul dan efisien dibandingkan arsitektur ResNet-50 dalam klasifikasi hama tanaman padi. Melalui pendekatan *transfer learning*, EfficientNet-B0 berhasil mencapai akurasi tertinggi sebesar 97,25%, nilai *F1-score* 97,65%, serta kestabilan kurva pelatihan yang konvergen sejak epoch awal. Inovasi *balancing efficiency and accuracy through systematic scaling* pada EfficientNet-B0 terbukti efektif dalam mempertahankan fitur-fitur spasial mikro (seperti detail antena, kaki, dan tekstur sayap serangga) sehingga mampu menekan tingkat kesalahan prediksi antarspesies serangga hingga di bawah 3%, bahkan pada citra dengan latar belakang sawah yang kompleks (*complex background*). Di sisi lain, ResNet-50 hanya mampu mencapai akurasi 95,85% dan

menunjukkan indikasi *overfitting* ringan akibat struktur sekuensial murninya yang cenderung menyerap derau (*noise*) latar belakang vegetasi. Dari aspek efisiensi komputasi, EfficientNet-B0 juga unggul secara signifikan dengan ukuran file model akhir yang jauh lebih ringkas, yaitu 25 MB, dibandingkan dengan ResNet-50 yang mencapai 98 MB. Dengan demikian, EfficientNet-B0 merupakan arsitektur yang paling direkomendasikan untuk pengembangan sistem proteksi tanaman padi otomatis karena menawarkan kombinasi optimal antara akurasi tinggi dan efisiensi memori.

REFERENCES

- [1] M. F. Akbar and D. A. Anggadimas, Nanda Martyan Sani, “Klasifikasi Citra Penyakit Daun Padi Dengan Metode CNN Menggunakan Arsitektur ResNet50V2,” *J. Comput. Eng. Syst. Sci.*, vol. 10, no. 1, pp. 299–311, 2025, doi: doi.org/10.24114/cess.v10i2.66960.
- [2] N. Istiqomah and M. Murintob, “Klasifikasi Penyakit Padi Berbasis Citra Daun Menggunakan Convolutional Neural Network (CNN),” *J. Sarj. Tek. Inform.*, vol. 12, no. 1, pp. 18–27, 2024, doi: [10.22146/jnteti.v14i3.18791](https://doi.org/10.22146/jnteti.v14i3.18791).
- [3] D. Saputra, A. F. Pratama, M. D. Fakhri, M. Ahsanur, and F. T. Anggraeny, “Klasifikasi Hama Serangga Pada Pertanian Menggunakan Arsitektur Inception-Resnet-V2,” *J. Ilm. Tek. Inform.*, vol. 19, no. 1, pp. 41–51, 2025, doi: [10.35457/antivirus.v19i1.4107](https://doi.org/10.35457/antivirus.v19i1.4107).
- [4] B. R. Prakosa, M. Ayu, D. Widya, and U. Mahdiah, “Klasifikasi Serangga Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN),” in *Seminar Nasional Inovasi Teknologi*, 2025, pp. 754–763. doi: [10.29407/k99dvg58](https://doi.org/10.29407/k99dvg58).
- [5] B. Kusuma, T. I. Hermanto, and C. D. Lestari, “Klasifikasi Jenis Penyakit Pada Tanaman Padi Menggunakan Algoritma Convolutional Neural Network,” *JIKO (Jurnal Inform. dan Komputer)*, vol. 9, no. 1, p. 40, 2025, doi: [10.26798/jiko.v9i1.1395](https://doi.org/10.26798/jiko.v9i1.1395).
- [6] H. N. Niko Pirnando, J. Petrus, and T. Tinaliah, “Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network dengan Arsitektur AlexNet,” *MDP Student Conf.*, vol. 4, no. 1, pp. 207–214, 2025, doi: [10.35957/mdp-sc.v4i1.11099](https://doi.org/10.35957/mdp-sc.v4i1.11099).
- [7] S. Yuliany, Aradea, and Andi Nur Rachman, “Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN),” *J. Buana Inform.*, vol. 13, no. 1, pp. 54–65, 2022, doi: [10.24002/jbi.v13i1.5022](https://doi.org/10.24002/jbi.v13i1.5022).
- [8] E. L. Mique and T. D. Palaoag, “Rice pest and disease detection using convolutional neural network,” in *ACM International Conference Proceeding Series*, 2018, pp. 147–151. doi: [10.1145/3209914.3209945](https://doi.org/10.1145/3209914.3209945).
- [9] C. R. Rahman *et al.*, “Identification and recognition of rice diseases and pests using convolutional neural networks,” *Biosyst. Eng.*, vol. 194, pp. 112–120, 2020, doi: [10.1016/j.biosystemseng.2020.03.020](https://doi.org/10.1016/j.biosystemseng.2020.03.020).
- [10] A. Akram, K. Fayakun, and H. Ramza, “Klasifikasi Hama Serangga pada Pertanian Menggunakan Metode Convolutional Neural Network,” *Build. Informatics, Technol. Sci.*, vol. 5, no. 2, pp. 397–406, 2023, doi: [10.47065/bits.v5i2.4063](https://doi.org/10.47065/bits.v5i2.4063).
- [11] A. T. Adiana, “Klasifikasi P enyakit Pada Daun Padi Menggunakan Model Hybrid,” vol. 15, no. 2, pp. 258–267, 2025, doi: [10.32664/smatika.v15i02.1548](https://doi.org/10.32664/smatika.v15i02.1548).
- [12] W. Liang, H. Zhang, G. Zhang, and H. XinCao, “Rice Blast Disease Recognition Using a Deep Convolutional Neural Network,” *Sci. Rep.*, vol. 9, pp. 1–10, 2019, doi: [10.1038/s41598-019-38966-0](https://doi.org/10.1038/s41598-019-38966-0).
- [13] A. Hasan, T. A. Layes, A. S. Afridi, S. H. Rifat, F. N. Nur, and N. N. Moon, “A comprehensive dataset of rice leaf images for disease detection using machine learning,” *Data Br.*, vol. 62, pp. 1–15, 2025, doi: [10.1016/j.dib.2025.111977](https://doi.org/10.1016/j.dib.2025.111977).
- [14] H. Ni *et al.*, “Classification of Typical Pests and Diseases of Rice Based on the ECA Attention Mechanism,” *Agric.*, vol. 13, no. 5, 2023, doi: [10.3390/agriculture13051066](https://doi.org/10.3390/agriculture13051066).
- [15] Y. Zheng, W. Zheng, and X. Du, “A lightweight rice pest detection algorithm based on improved YOLOv8,” *Sci. Rep.*, vol. 14, no. 1, 2024, doi: [10.1038/s41598-024-81587-5](https://doi.org/10.1038/s41598-024-81587-5).
- [16] M. T. Roseno, S. Oktarina, Y. Nearti, H. Syaputra, and N. Jayanti, “Comparing CNN Models for Rice Disease Detection: ResNet50, VGG16, and MobileNetV3-Small,” *J. Inf. Syst. Informatics*, vol. 6, no. 3, pp. 2099–2109, 2024, doi: [10.51519/journalisi.v6i3.865](https://doi.org/10.51519/journalisi.v6i3.865).