



Evolusi Performa Arsitektur Deep Learning melalui Optimasi Bertahap dan Interpretabilitas Grad-CAM untuk Klasifikasi Penyakit Ikan Air Tawar

Sasa Kirana Wulandari^{1*}, Fachruddin Fachruddin², Jasmir Jasmir³

¹⁻³ Magister Sistem Informasi, Fakultas Ilmu Komputer, Universitas Dinamika Bangsa, Indonesia

Email: Shasa.kirana78@gmail.com^{1*}, fachruddin.stikom@gmail.com², ijay_jasmir@yahoo.com³

Alamat: Jl. Jend. Sudirman, The Hok, Kec. Jambi Sel., Kota Jambi, Jambi 36138 (11pt, Times New Roman)

Penulis Korespondensi: Shasa.kirana78@gmail.com

Abstract. *Freshwater fish diseases significantly affect aquaculture productivity and economic sustainability, while accurate visual classification remains challenging due to interclass similarity and image variability. This study presents a comparative evaluation of three deep learning architectures—DenseNet201, ResNet50, and EfficientNetV2-S—using a stepwise optimization strategy combined with Gradient-weighted Class Activation Mapping (Grad-CAM) for freshwater fish disease classification. Models were trained through three phases: baseline, optimized, and fine-tuned. Performance was evaluated using accuracy, precision, recall, F1 score, Matthews correlation coefficient (MCC), Cohen's kappa, and per-class ROC-AUC. Results show consistent performance improvement across all architectures, with EfficientNetV2-S achieving the highest accuracy (97.14%), followed by ResNet50 (96.11%) and DenseNet201 (94.40%). High ROC-AUC values (>0.98) indicate strong discriminative capability. Grad-CAM analysis confirms that all optimized models focus on biologically relevant lesion regions, enhancing model transparency and reliability.*

Keywords: Deep Learning; Fish Disease Classification; GradCAM; Model Optimization; Transfer Learning

Abstrak. Penyakit ikan air tawar berdampak signifikan terhadap produktivitas dan keberlanjutan ekonomi akuakultur, sementara klasifikasi penyakit berbasis visual masih menantang akibat kesamaan antar kelas dan variasi kondisi citra. Penelitian ini menyajikan evaluasi komparatif tiga arsitektur deep learning—DenseNet201, ResNet50, dan EfficientNetV2-S—menggunakan strategi optimasi bertahap yang dikombinasikan dengan *Gradient-weighted Class Activation Mapping* (Grad-CAM) untuk klasifikasi penyakit ikan air tawar. Model dilatih melalui tiga fase, yaitu *baseline*, *optimized*, dan *fine-tuned*. Kinerja model dievaluasi menggunakan akurasi, presisi, recall, skor F1, *Matthews correlation coefficient* (MCC), kappa Cohen, dan ROC-AUC per kelas. Hasil menunjukkan peningkatan performa yang konsisten pada seluruh arsitektur, dengan EfficientNetV2-S mencapai akurasi tertinggi sebesar 97,14%, diikuti oleh ResNet50 sebesar 96,11% dan DenseNet201 sebesar 94,40%. Nilai ROC-AUC yang tinggi (>0,98) menunjukkan kemampuan diskriminatif yang kuat. Analisis Grad-CAM mengonfirmasi bahwa seluruh model yang dioptimalkan berfokus pada area lesi yang relevan secara biologis, sehingga meningkatkan transparansi dan keandalan sistem.

Kata kunci: Deep Learning; Grad-CAM; Klasifikasi Penyakit Ikan; Optimasi Model; Transfer Learning.

1. LATAR BELAKANG

Akuakultur air tawar memiliki peran penting dalam mendukung ketahanan pangan dan stabilitas ekonomi global, khususnya di negara-negara berkembang (Bernery et al., 2022). Spesies ikan air tawar yang umum dibudidayakan, seperti nila, lele, ikan mas, dan gurami, termasuk komoditas utama karena kemampuan adaptasi lingkungan yang tinggi serta nilai ekonomi yang signifikan (Das & Mandal, 2022). Di kawasan Asia Tenggara, sektor akuakultur air tawar menjadi pilar utama mata pencaharian pedesaan (Suzuki, 2021; Tezzo et al., 2021),

dengan Indonesia sebagai kontributor terbesar yang menyumbang sekitar 43% produksi perikanan air tawar regional dan lebih dari 60% produksi perikanan nasional (Rimmer et al., 2021). Namun, penyakit ikan masih menjadi tantangan utama yang menghambat produktivitas dan keberlanjutan ekonomi budidaya perikanan (Roscher et al., 2022).

Penyakit ikan air tawar umumnya disebabkan oleh infeksi bakteri, virus, parasit, dan jamur, serta faktor non-infeksius seperti stres lingkungan dan ketidakseimbangan nutrisi (Mohanty & Sahoo, 2025). Dalam praktiknya, diagnosis penyakit masih didominasi oleh pemeriksaan visual manual dan analisis laboratorium, yang bersifat subjektif, memakan waktu, serta kurang sesuai untuk pengambilan keputusan secara real-time dalam skala budidaya yang besar (MacAulay et al., 2022). Seiring perkembangan kecerdasan buatan (AI), khususnya *deep learning* berbasis *computer vision*, pendekatan otomatis untuk deteksi penyakit ikan mulai dikembangkan sebagai alternatif yang lebih objektif dan efisien.

Convolutional Neural Networks (CNN) mampu mengekstraksi fitur visual secara langsung dari citra dan telah menunjukkan kinerja yang baik dalam mendeteksi kelainan morfologis pada ikan air tawar, seperti luka, perubahan warna, dan kerusakan jaringan (Archana & Jeevaraj, 2024). Namun, sebagian besar studi yang ada masih berfokus pada pelaporan kinerja akhir model dengan menggunakan satu arsitektur atau satu konfigurasi pelatihan, tanpa mengevaluasi bagaimana performa model berkembang selama proses optimasi maupun bagaimana desain arsitektur memengaruhi ketahanan dan kemampuan generalisasi model (Liao et al., 2022).

Keterbatasan serupa juga ditemukan pada penelitian sebelumnya, di mana model berbasis CNN mencapai akurasi yang relatif tinggi namun masih terbatas pada penggunaan arsitektur tunggal dan belum menyediakan interpretasi visual terhadap keputusan model (Mamun et al., 2023; Wulandari & Jasmir, 2024). Kondisi ini menyisakan kesenjangan penelitian terkait pemahaman evolusi performa model selama proses optimasi serta pengaruh desain arsitektur terhadap ketahanan dan generalisasi model pada klasifikasi penyakit ikan air tawar.

Selain akurasi, transparansi model merupakan faktor penting dalam penerapan sistem berbasis *deep learning* di bidang akuakultur. Banyak model CNN masih dipandang sebagai *black box* yang menghasilkan prediksi tanpa penjelasan yang memadai, sehingga membatasi tingkat kepercayaan dan adopsi teknologi oleh praktisi (Sultana et al., 2024). Pendekatan *Explainable Artificial Intelligence (XAI)*, khususnya melalui metode *Gradient-weighted Class Activation Mapping (Grad-CAM)*, menawarkan mekanisme visual untuk menyoroti area citra

yang paling berkontribusi terhadap hasil klasifikasi. Pendekatan ini memungkinkan validasi bahwa keputusan model didasarkan pada ciri patologis yang relevan secara biologis (Ghnemat et al., 2023; Giuffrida et al., 2025).

Oleh karena itu, penelitian ini bertujuan untuk menganalisis evolusi performa beberapa arsitektur *deep learning* melalui strategi optimasi bertahap serta mengintegrasikan interpretabilitas visual berbasis Grad-CAM, guna menghasilkan sistem klasifikasi penyakit ikan air tawar yang robust, transparan, dan relevan untuk aplikasi akuakultur nyata. Pemilihan arsitektur DenseNet201, ResNet50, dan EfficientNetV2-S didasarkan pada karakteristik struktural yang saling melengkapi. DenseNet201 memanfaatkan mekanisme *dense connectivity* untuk meningkatkan pemanfaatan ulang fitur dan menangkap perbedaan visual yang halus (Tang et al., 2024). ResNet50 menggunakan *residual connections* untuk menjaga stabilitas pelatihan pada jaringan yang dalam, menjadikannya referensi yang andal dalam menganalisis evolusi performa selama proses optimasi (Ambar et al., 2025; Zhao & Leong, 2025). Sementara itu, EfficientNetV2-S dirancang untuk mencapai keseimbangan antara akurasi dan efisiensi komputasi melalui strategi *training-aware scaling*, sehingga relevan untuk penerapan sistem klasifikasi penyakit ikan di lingkungan akuakultur dengan keterbatasan sumber daya (Hariri et al., 2025).

2. KAJIAN TEORITIS

Kajian teoritis ini disusun untuk memberikan landasan konseptual dan empiris bagi penerapan deep learning dalam klasifikasi penyakit ikan air tawar. Pembahasan diawali dengan teori dasar pengenalan pola visual, dilanjutkan dengan pendekatan deep learning yang telah terbukti efektif dalam penelitian sebelumnya, serta mencakup aspek optimasi, evaluasi, dan interpretabilitas model yang relevan untuk sistem diagnosis berbasis citra.

A. Pengenalan Pola Visual dan *Computer Vision* dalam Diagnosis Biologis

Penyakit ikan air tawar umumnya memunculkan perubahan visual yang dapat diamati secara eksternal, seperti luka terbuka, bercak putih akibat infeksi jamur, perubahan warna tubuh akibat infeksi virus, iritasi akibat parasit, serta kerusakan jaringan non-infeksius akibat faktor lingkungan atau mekanis (Cardoso et al., 2021). *Computer vision* berkembang sebagai pendekatan ilmiah untuk mengekstraksi dan mengenali pola dari data citra secara otomatis, menggantikan inspeksi visual manusia yang cenderung subjektif dan tidak konsisten (Mandal & Ghosh, 2024). Penelitian (Hasan et al., 2022) dalam akuakultur

menunjukkan bahwa sistem diagnosis berbasis *computer vision* mampu meningkatkan konsistensi, kecepatan, dan efisiensi pemantauan kesehatan ikan dibandingkan metode manual, sehingga menjadi fondasi bagi penerapan pembelajaran berbasis data dalam diagnosis penyakit ikan.

B. Convolutional Neural Networks sebagai Model Representasi Visual

Convolutional Neural Networks (CNN) dikembangkan sebagai arsitektur yang mampu mengekstraksi fitur visual secara hierarkis melalui mekanisme *local receptive fields*, *weight sharing*, dan *hierarchical feature learning* (Virginia et al., 2025). Dalam berbagai studi pada citra biologis dan medis, CNN terbukti mampu mengenali perbedaan visual yang halus dan kompleks, termasuk pola lesi dan kerusakan jaringan (Shubham et al., 2023). Dalam konteks akuakultur, studi (Huang & Khabusi, 2023) mengonfirmasi bahwa CNN merupakan pendekatan yang efektif dan stabil untuk klasifikasi kondisi kesehatan ikan berbasis citra.

C. Transfer Learning dalam Klasifikasi Citra Biologis

Meskipun CNN efektif dalam ekstraksi fitur visual, pelatihan model dari awal memerlukan dataset besar dan sumber daya komputasi yang tinggi. Untuk mengatasi keterbatasan tersebut, *transfer learning* diperkenalkan sebagai pendekatan untuk memanfaatkan representasi visual dari model yang telah dilatih pada dataset skala besar (Gholizade et al., 2025). Penelitian (Kalusivalingam et al., 2021) menunjukkan bahwa *transfer learning* mampu mempercepat konvergensi pelatihan, meningkatkan akurasi, dan menjaga stabilitas model pada dataset terbatas, khususnya dalam klasifikasi citra medis dan biologis. Pendekatan ini juga terbukti efektif dalam klasifikasi penyakit ikan, di mana model *pre-trained* memberikan performa yang lebih konsisten dibandingkan pelatihan dari awal (Ergün, 2025).

D. Optimasi Model dan Kemampuan Generalisasi

Keberhasilan model *deep learning* tidak hanya ditentukan oleh performa pada data pelatihan, tetapi juga oleh kemampuannya dalam melakukan generalisasi terhadap data yang belum pernah dilihat sebelumnya (Zhang et al., 2021). Perbedaan kinerja antara data pelatihan dan data pengujian dikenal sebagai *generalization gap*, yang umumnya muncul akibat *overfitting* (Yang et al., 2023). Berbagai strategi optimasi, seperti augmentasi data, regularisasi (dropout dan L2), serta *fine-tuning* bertahap, telah terbukti efektif dalam mengurangi *overfitting* dan meningkatkan stabilitas performa model (Nishat, 2024). Selain

itu, pemantauan evolusi performa selama proses pelatihan memberikan pemahaman yang lebih komprehensif dibandingkan evaluasi kinerja akhir semata (Ibrahim et al., 2024).

E. Evaluasi Kinerja dan Validitas Model Klasifikasi

Dalam klasifikasi multikelas, akurasi saja tidak cukup untuk menggambarkan kinerja model secara menyeluruh (Barulina et al., 2023). Oleh karena itu, diperlukan metrik evaluasi tambahan untuk menilai keandalan model secara lebih komprehensif (Owusu-Adjei et al., 2023). Presisi, *recall*, dan skor F1 banyak digunakan untuk mengukur ketepatan dan kelengkapan prediksi, dengan skor F1 memberikan keseimbangan antara keduanya (Canbek et al., 2022). Selain itu, *Matthews Correlation Coefficient* (MCC) dan *Cohen's Kappa* digunakan untuk menilai konsistensi prediksi dengan mempertimbangkan seluruh elemen matriks kebingungan dan kesepakatan kebetulan, sehingga cocok untuk klasifikasi multikelas (Diallo et al., 2024). ROC–AUC juga digunakan untuk mengevaluasi kemampuan diskriminatif model pada berbagai ambang keputusan, khususnya melalui analisis per kelas (Giudici et al., 2025).

F. Interpretabilitas Model dan *Explainable Artificial Intelligence*

Selain kinerja kuantitatif, interpretabilitas model merupakan aspek krusial dalam penerapan *deep learning* di bidang biologi dan kesehatan (Teng et al., 2022). Model CNN sering dianggap sebagai *black box* karena sulitnya memahami dasar pengambilan keputusan model (Szandała, 2023). Untuk mengatasi hal tersebut, *Explainable Artificial Intelligence* (XAI) dikembangkan guna memberikan penjelasan atas prediksi model (Minh et al., 2022). Salah satu metode XAI yang paling umum digunakan adalah *Gradient-weighted Class Activation Mapping* (Grad-CAM), yang memvisualisasikan area citra yang paling berkontribusi terhadap prediksi kelas tertentu (Guluwadi, 2024). Penelitian (Isaac et al., 2024) menunjukkan bahwa Grad-CAM efektif dalam memverifikasi fokus model pada area patologi penyakit ikan yang relevan secara biologis, sehingga meningkatkan kepercayaan dan validitas hasil klasifikasi.

G. Sintesis Kajian Teoritis

Berdasarkan kajian teoritis dan penelitian sebelumnya, dapat disimpulkan bahwa klasifikasi penyakit ikan air tawar secara otomatis memerlukan pendekatan yang akurat, robust, dan dapat dijelaskan. CNN berbasis *transfer learning* terbukti efektif dalam mengekstraksi fitur visual dari citra biologis, sementara strategi optimasi bertahap berperan penting dalam meningkatkan kemampuan generalisasi model. Evaluasi menggunakan


metrik yang komprehensif serta integrasi interpretabilitas berbasis XAI menjadi faktor kunci dalam memastikan keandalan dan validitas sistem diagnosis berbasis *deep learning*.

3. METODE PENELITIAN

Metode penelitian ini disusun sebagai peta jalan sistematis untuk mengembangkan dan mengevaluasi model *deep learning* dalam klasifikasi penyakit ikan air tawar secara akurat. Uraian dimulai dari rancangan eksperimen berbasis evolusi performa tiga fase, prosedur prapemrosesan dan pembagian data menggunakan skema 60:20:20, hingga penerapan teknik *Explainable AI* (XAI) untuk memvalidasi transparansi diagnosis model. Seluruh tahapan ini diintegrasikan guna memastikan bahwa sistem yang dibangun memiliki reliabilitas statistik sekaligus interpretabilitas visual yang kuat dalam mendukung keputusan manajemen akuakultur.

A. Desain Penelitian

Penelitian ini menggunakan desain eksperimental kuantitatif yang berfokus pada pengembangan dan evaluasi model klasifikasi citra digital. Inti dari desain penelitian adalah pemantauan evolusi performa model secara bertahap untuk meminimalkan generalization gap antara data latih dan data uji. Secara konseptual, desain ini mencakup siklus hidup data mulai dari *input* gambar citra, ekstraksi fitur otomatis, hingga luaran diagnosis yang divalidasi secara visual, sebagaimana dipetakan pada Gambar 1.



Keterangan: Siklus dari input citra hingga validasi visual
Sumber: Generated by Napkin (2026)

Gambar 1. Siklus Terintegrasi Diagnosis Penyakit Ikan Berbasis Deep Learning

Pada Gambar 1. alur dimulai dari tahap *Input & Preprocessing* yang merupakan gerbang utama di mana citra penyakit ikan air tawar dimasukkan dan diolah agar seragam. Selanjutnya, masuk ke tahap *Feature Extraction* di sini model *deep learning* bekerja layaknya mikroskop digital yang membedah pola visual, tekstur kulit, dan karakteristik luka pada ikan. Setelah fitur-fitur unik ditemukan, proses berlanjut ke *Classification* menggunakan lapisan *Softmax* untuk menentukan label penyakit berdasarkan probabilitas tertinggi dari 7 kategori yang ada. Siklus ini ditutup dengan *Visual Validation* menggunakan Grad-CAM untuk memastikan bahwa area yang dideteksi AI sesuai dengan lokasi infeksi secara biologis, sehingga menghasilkan *Final Output* berupa laporan diagnosis yang kredibel bagi pengguna.

B. Populasi dan Sampel Penelitian

Populasi penelitian mencakup citra digital penyakit ikan air tawar yang bersumber dari dataset sekunder repositori Kaggle pada Table 1.

Tabel 1. Informasi Dataset

Nama	Pemilik	Tautan
<i>Freshwater Fish Disease Aquaculture in south asia</i>	SUBIR BISWAS19	https://www.kaggle.com/datasets/subirbiswas19/freshwater-fish-disease-aquaculture-in-south-asia/data

Sumber: Kaggle, penelitian dari (Biswas et al., 2024)


Penentuan sampel dilakukan menggunakan teknik *random splitting* dengan rasio 60:20:20, di mana 60% data digunakan sebagai data latih (*Dir Train*), 20% sebagai data validasi (*Dir Val*) untuk memantau stabilitas performa model, dan 20% sebagai data uji (*Dir Test*) yang sepenuhnya terpisah untuk mengevaluasi kemampuan generalisasi model secara objektif.

C. Teknik dan Instrumen Pengumpulan Data

Pengumpulan data dilakukan secara digital melalui proses standarisasi citra ke ukuran 224×224 piksel dan normalisasi nilai piksel agar sesuai dengan kebutuhan arsitektur *deep learning*. Untuk meningkatkan reliabilitas instrumen dan memperkaya variasi data latih, diterapkan teknik data *augmentation* berupa rotasi, pergeseran (*shift*), dan *zoom*. Pendekatan ini bertujuan mengurangi risiko *overfitting* serta meningkatkan kemampuan model dalam mengenali variasi pola patologis yang beragam.

D. Alat Analisis Data dan Model Penelitian

Analisis dilakukan menggunakan bahasa pemrograman Python dengan pustaka *TensorFlow*. Model penelitian membandingkan tiga arsitektur utama, yaitu ResNet50, DenseNet201, dan EfficientNetV2-S. Prosedur eksperimen dijalankan melalui alur yang melibatkan tiga fase optimasi sistematis (*Baseline*, *Optimized*, *Fine-tune*) dan evaluasi tujuh metrik performa, yang disajikan secara mendalam pada Gambar 3.



Keterangan: Alur teknis pelatihan model dari pembagian data hingga evaluasi metrik.

Sumber: Hasil Olahan Peneliti (2026).


Gambar 2. Alur Eksperimen Pelatihan Model dan Evaluasi Performa

Gambar 2 memperlihatkan proses *merge & split data* dengan rasio 60:20:20, dilanjutkan dengan *data augmentation* pada data latih. Selanjutnya, model dilatih melalui tiga fase optimasi, yaitu *baseline*, *optimized*, dan *fine-tune*, dengan pemantauan *generalization gap* pada setiap fase. Proses ini diakhiri dengan evaluasi performa menggunakan tujuh metrik evaluasi utama sebelum model disimpan dalam format *.h5* atau *.keras*.

E. Analisis Validitas dan Interpretasi Model (Grad-CAM)

Validitas model tidak hanya dievaluasi berdasarkan metrik numerik, tetapi juga melalui interpretasi visual menggunakan metode *Explainable Artificial Intelligence* (XAI) berbasis Grad-CAM. Teknik ini digunakan untuk memvisualisasikan area citra yang paling berkontribusi terhadap prediksi model, sehingga memungkinkan verifikasi biologis terhadap

keputusan klasifikasi. Alur operasional diagnosis yang mengintegrasikan prediksi model dengan visualisasi Grad-CAM ini ditunjukkan pada Gambar 3.



Keterangan: Tahapan implementasi diagnosis citra dan visualisasi heatmap

Sumber: Hasil Olahan Peneliti (2026).

Gambar 3. Alur Operasional Sistem Diagnosis dan Visualisasi Grad-CAM

Pada Gambar 3, proses dimulai dengan *load model* beserta lapisan konvolusi terakhir. Setelah pengguna memasukkan citra (*image input*), sistem melakukan validasi dan prapemrosesan sebelum mengeksekusi Grad-CAM. Algoritma Grad-CAM menghitung gradien dari kelas yang diprediksi terhadap aktivasi lapisan konvolusi untuk menghasilkan *heatmap*. *Heatmap* ini ditumpangkan pada citra asli sebagai bukti visual area patologis yang menjadi dasar pengambilan keputusan model.

4. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pengujian dan pembahasan kinerja tiga arsitektur deep learning dalam klasifikasi penyakit ikan air tawar. Analisis dilakukan secara bertahap, dimulai dari karakteristik dataset, evolusi performa pada setiap fase optimasi, evaluasi kinerja global menggunakan metrik statistik, hingga validasi visual keputusan model menggunakan teknik Explainable AI.


A. Proses Pengumpulan Data dan Lingkup Penelitian

Dataset yang digunakan dalam penelitian ini berasal dari *Kaggle Freshwater Fish Disease Aquaculture Dataset* yang mencakup tujuh kelas kondisi kesehatan ikan air tawar, yaitu *Healthy*, *Bacterial Red Disease*, *Bacterial Gill Disease*, *Aeromoniasis*, *Fungal Saprolegniasis*, *Parasitic Diseases*, dan *Viral White Tail Disease*. Dataset dikurasi dan dibagi ke dalam tiga subset, yaitu data latih (60%), validasi (20%), dan uji (20%). Seluruh citra melalui tahap *preprocessing* berupa standarisasi ukuran dan normalisasi nilai piksel sebelum digunakan dalam pelatihan model. Eksperimen dilakukan pada lingkungan komputasi berbasis GPU menggunakan Google Colab dengan konfigurasi pelatihan yang seragam untuk memastikan perbandingan yang adil antar arsitektur.

B. Evolusi Performa Model pada Setiap Fase Optimasi

Analisis ini bertujuan untuk mengevaluasi bagaimana performa model berkembang sepanjang proses pelatihan melalui tiga fase optimasi, yaitu *baseline*, *optimized*, dan *fine-tuned*. Adapun perbandingan performa akurasi validasi antar fase dapat dilihat pada Gambar 4.

1) Perbandingan Akurasi Validasi Antar Fase



Keterangan: Progresi akurasi validasi model *DenseNet201*, *ResNet50*, dan *EfficientNetV2-S* pada setiap fase optimasi.

Sumber: Hasil Olahan Peneliti (2026).


Gambar 4. Perbandingan Akurasi Validasi Antar Fase

Gambar 4 menunjukkan progresi akurasi validasi pada ketiga arsitektur. Pada fase *baseline*, seluruh model telah menunjukkan performa awal yang relatif tinggi, dengan ResNet50 memperoleh akurasi validasi tertinggi. Setelah fase *optimized*, seluruh arsitektur mengalami peningkatan performa yang konsisten. Peningkatan paling signifikan terjadi pada

EfficientNetV2-S pada fase *fine-tuned*, yang mengindikasikan kemampuan adaptasi yang baik terhadap pelepasan lapisan parsial dan penyesuaian *learning rate*.

2) Analisis Ablasi, Akurasi Progresif, dan Generalization Gap

Bagian ini menyajikan evaluasi mendalam terhadap kontribusi setiap fase optimasi terhadap performa akhir model dan kemampuannya dalam melakukan generalisasi pada data baru, Adapun hasilnya dapat dilihat pada Gambar 5.



Keterangan: Analisis *ablation study* akurasi dan *Generalization gap* pada tiga arsitektur deep learning
Sumber: Hasil Olahan Peneliti (2026).


Gambar 5. Analisis Progresi Akurasi dan Generalization Gap

Gambar 5 secara komprehensif memperlihatkan bagaimana setiap fase optimasi berkontribusi terhadap peningkatan performa model sekaligus menjaga stabilitas generalisasinya. Hasil *ablation study* pada grafik kiri menunjukkan bahwa fase *optimized* berhasil meningkatkan stabilitas awal, sementara fase *fine-tuned* berperan krusial dalam memaksimalkan representasi fitur tingkat tinggi melalui penyesuaian bobot pada lapisan tertentu. ResNet50 menunjukkan peningkatan akurasi yang stabil antar fase, sedangkan EfficientNetV2-S memperlihatkan peningkatan tajam pada fase akhir, mengindikasikan efisiensi arsitektur tersebut dalam memanfaatkan strategi *training-aware scaling*.

Sejalan dengan peningkatan akurasi, grafik *generalization gap* pada bagian kanan menunjukkan efektivitas strategi optimasi bertahap dalam menekan risiko *overfitting*. Pada fase *baseline*, seluruh model menunjukkan *gap* yang relatif tinggi di atas ambang batas sehat 5%. Namun, setelah melalui fase *optimized* dan *fine-tuned*, nilai *generalization gap* menurun secara signifikan, khususnya pada ResNet50 yang mencapai *gap* terendah (0.0380) dan EfficientNetV2-S yang tetap berada dalam batas toleransi generalisasi yang sehat. Integrasi kedua analisis ini membuktikan bahwa skema pelatihan yang diterapkan berhasil mencapai keseimbangan optimal antara akurasi tinggi dan kemampuan generalisasi model yang kuat.

C. Konvergensi Akurasi dan Loss Global

Analisis konvergensi merupakan tahap krusial untuk memantau stabilitas proses pembelajaran model pada setiap fase eksperimen. Stabilitas ini diukur melalui pergerakan kurva akurasi dan loss untuk memastikan model tidak terjebak dalam kondisi *overfitting* atau *underfitting* yang ekstrem sebelum evaluasi akhir dilakukan.



Keterangan: Konvergensi akurasi dan *loss* pelatihan serta validasi pada fase *baseline*, *optimized*, dan *fine-tuned*.

Sumber: Hasil Olahan Peneliti (2026).

Gambar 6. Perbandingan Konvergensi Akurasi dan *Loss*


Gambar 6(a) dan 6(b) memperlihatkan dinamika konvergensi akurasi dan *loss* pelatihan serta validasi sepanjang seluruh epoch. Pada fase *baseline*, fluktuasi akurasi validasi masih terlihat cukup signifikan. Setelah fase *optimized*, kurva akurasi dan *loss* menunjukkan konvergensi yang lebih stabil. Fase *fine-tuned* menghasilkan kurva yang paling konsisten, dengan selisih antara pelatihan dan validasi yang semakin kecil, yang menegaskan keberhasilan strategi optimasi bertahap dalam meningkatkan stabilitas dan generalisasi model.

Setelah fase *optimized*, kurva akurasi dan *loss* menunjukkan pola konvergensi yang lebih stabil. Pada fase *fine-tuned*, seluruh model memperlihatkan kurva yang paling konsisten, dengan selisih antara pelatihan dan validasi yang semakin kecil. Hal ini menegaskan keberhasilan strategi optimasi bertahap dalam meningkatkan stabilitas pelatihan dan kemampuan generalisasi model.

D. Evaluasi Kinerja Global Model

Evaluasi kinerja global dilakukan untuk menilai reliabilitas dan konsistensi prediksi ketiga model deep learning pada seluruh kategori penyakit ikan air tawar.

1) Perbandingan Metrik Evaluasi Multidimensi




Keterangan: Perbandingan kinerja ketiga model menggunakan metrik
Sumber: Hasil Olahan Peneliti (2026).

Gambar 7. Perbandingan Kinerja Global

Berdasarkan Gambar 7, perbandingan metrik multidimensi menunjukkan bahwa EfficientNetV2-S mencapai performa tertinggi pada seluruh metrik utama, termasuk akurasi, presisi, *recall*, F1-score, dan *Matthews Correlation Coefficient* (MCC), diikuti oleh ResNet50 dan DenseNet201. Nilai MCC yang tinggi pada EfficientNetV2-S mengindikasikan konsistensi prediksi yang kuat di seluruh kelas, sehingga menegaskan keandalan model dalam skenario klasifikasi multikelas dengan karakteristik visual yang beragam.

2) Perbandingan Confusion Antar Kelas dan Antar Arsitektur

Analisis *confusion matrix* digunakan untuk mengidentifikasi pola kesalahan prediksi antar kelas secara spesifik. Tahap ini memungkinkan peneliti melihat kelas penyakit mana yang sering tertukar oleh model karena kemiripan ciri visual biologisnya.



Keterangan: Perbandingan *confusion matrix* hasil klasifikasi penyakit ikan air tawar pada masing-masing arsitektur.

Sumber: Hasil Olahan Peneliti (2026).


Gambar 8. Perbandingan Confusion Matrix Antar Model

Gambar 8 menunjukkan perbedaan pola kesalahan antar arsitektur. DenseNet201 masih memperlihatkan kesalahan klasifikasi pada kelas penyakit dengan ciri visual yang mirip, sedangkan ResNet50 menunjukkan pemisahan kelas yang lebih baik. EfficientNetV2-S

menghasilkan matriks yang paling diagonal, menandakan tingkat kesalahan klasifikasi yang minimal dan kemampuan pemisahan kelas yang optimal.

3) Analisis ROC AUC Antar Model

Daya diskriminasi model diukur melalui kurva ROC untuk mengetahui seberapa baik model dapat memisahkan antara satu kategori penyakit dengan kategori lainnya pada berbagai ambang batas klasifikasi.



Keterangan: Kurva ROC–AUC per kelas untuk *DenseNet201*, *ResNet50*, dan *EfficientNetV2-S*.
Sumber: Hasil Olahan Peneliti (2026).


Gambar 9. Perbandingan Nilai ROC AUC Model

Kurva ROC pada Gambar 9. menunjukkan bahwa seluruh model memiliki nilai AUC yang tinggi pada setiap kelas, dengan *EfficientNetV2-S* secara konsisten mencapai nilai AUC tertinggi. Hal ini menunjukkan kemampuan diskriminatif yang sangat baik dalam membedakan masing-masing kategori penyakit ikan air tawar.

H. Interpretasi Visual Menggunakan Grad-CAM

Sebagai tahap akhir validasi, teknik *Gradient-weighted Class Activation Mapping* (Grad-CAM) digunakan untuk memberikan transparansi terhadap keputusan klasifikasi model. Teknik ini memastikan bahwa model memberikan diagnosis berdasarkan fitur patologis ikan, bukan berdasarkan kebisingan di latar belakang citra.


1) Hasil GradCAM Pada Test Dir



Keterangan: Visualisasi *heatmap* Grad-CAM pada area infeksi penyakit ikan pada Direktori Test
Sumber: Hasil Olahan Peneliti (2026).

Gambar 10. Visualisasi Interpretasi Model dengan Grad-CAM.

2) Hasil Upload Gambar GradCAM



Keterangan: Visualisasi *heatmap* Grad-CAM dengan *upload* gambar
Sumber: Hasil Olahan Peneliti (2026).

Gambar 11. Visualisasi Interpretasi Model dengan Grad-CAM.

Grad-CAM menunjukkan bahwa ketiga arsitektur yang diuji telah berhasil melakukan lokalisasi fitur patologis secara akurat, di mana area aktivasi utama (*heatmap*) terfokus pada manifestasi klinis penyakit dan bukan pada kebisingan latar belakang citra. EfficientNetV2-S menunjukkan keunggulan dalam presisi visual dengan menghasilkan area fokus yang paling tajam dan terpusat, terutama pada gejala spesifik seperti infeksi insang pada kelas *Bacterial*

gill disease. Ketajaman interpretasi ini berkorelasi positif dengan performa puncaknya yang mencatatkan nilai MCC 0.9667 dan Akurasi 0.9714, membuktikan bahwa keputusan model didasarkan pada karakteristik biologis yang paling relevan.

Di sisi lain, ResNet50 dan DenseNet201 cenderung menghasilkan sebaran aktivasi yang lebih luas (difus), yang mencakup jaringan sehat di sekitar area infeksi. Meskipun DenseNet201 mampu memberikan tingkat konfidensi prediksi yang sangat tinggi hingga 98.35%, visualisasi Grad-CAM mengungkap ketergantungannya pada fitur tekstur global tubuh ikan dibandingkan lokalisasi fitur patologis yang spesifik. Konsistensi seluruh model dalam menempatkan *heatmap* pada objek ikan di berbagai kelas penyakit, seperti *White tail disease* dan *Parasitic diseases*, memvalidasi rendahnya nilai *generalization gap* (hingga 0.0319 pada fase optimasi), yang menegaskan bahwa model memiliki kemampuan generalisasi yang kuat dengan mengabaikan informasi non-esensial dari lingkungan sekitar citra.

5. KESIMPULAN DAN SARAN

Penelitian ini secara kritis menyimpulkan bahwa implementasi arsitektur *deep learning* melalui strategi optimasi tiga fase—*baseline*, *optimized*, dan *fine-tuned*—efektif dalam meningkatkan akurasi diagnosis penyakit ikan air tawar. Berdasarkan fakta hasil pengujian, model EfficientNetV2-S menunjukkan performa paling unggul dengan tingkat akurasi mencapai 97,14% dan nilai MCC sebesar 0,9667, yang mengindikasikan reliabilitas prediksi yang sangat kuat dan konsisten di seluruh kategori penyakit. Temuan ini membuktikan bahwa penggunaan arsitektur dengan mekanisme *training-aware scaling* mampu menangkap fitur patologis yang kompleks lebih baik dibandingkan arsitektur ResNet50 dan DenseNet201. Selain itu, integrasi teknologi Grad-CAM berhasil memberikan transparansi keputusan model dengan memvisualisasikan fokus spasial pada area infeksi yang sesuai secara klinis, sehingga menjawab tantangan mengenai aspek interpretabilitas dalam kecerdasan buatan untuk bidang akuakultur.

Meskipun hasil penelitian menunjukkan performa yang sangat tinggi, terdapat keterbatasan terkait variasi data primer yang diambil langsung dari kondisi kolam budidaya dengan tingkat kekeruhan air yang berbeda-beda. Peneliti menyarankan agar berhati-hati dalam melakukan generalisasi model pada lingkungan lapangan yang memiliki gangguan visual ekstrem di luar *dataset* laboratorium. Oleh karena itu, rekomendasi untuk penelitian selanjutnya adalah melakukan perluasan *dataset* dengan mencakup citra ikan dari berbagai kondisi lingkungan

kolam yang lebih dinamis serta menguji implementasi model pada perangkat seluler agar lebih aplikatif bagi pembudidaya. Selain itu, disarankan adanya eksplorasi terhadap teknik penggabungan model (*ensemble learning*) untuk menutupi kelemahan spesifik pada masing-masing arsitektur guna mencapai stabilitas diagnosis yang lebih sempurna di masa depan.

DAFTAR REFERENSI

- Ambar, M. K., Oztoprak, H., & Yurtkan, K. (2025). Optimizing ResNet-50 for multiclass classification: A Multi-Stage Learning Approach. *IEEE Access*.
- Archana, R., & Jeevaraj, P. S. E. (2024). Deep learning models for digital image processing: a review. *Artificial Intelligence Review*, 57(1), 11.
- Barulina, M., Okunkov, S., Ulitin, I., & Sanbaev, A. (2023). Sensitivity of modern deep learning neural networks to unbalanced datasets in multiclass classification problems. *Applied Sciences*, 13(15), 8614.
- Bernery, C., Bellard, C., Courchamp, F., Brosse, S., Gozlan, R. E., Jarić, I., Teletchea, F., & Leroy, B. (2022). Freshwater fish invasions: A comprehensive review. *Annual Review of Ecology, Evolution, and Systematics*, 53(1), 427–456.
- Biswas, S., Muduli, D., Islam, M. A., Kanade, A. S., Zamani, A. T., Kanade, S. P., & Parveen, N. (2024). Empirical Evaluation of Deep Learning Techniques for Fish Disease Detection in Aquaculture Systems: A Transfer Learning and Fusion-Based Approach. *IEEE Access*, 12, 176136–176154. <https://doi.org/10.1109/ACCESS.2024.3504283>
- Canbek, G., Taskaya Temizel, T., & Sagioglu, S. (2022). PToPI: A comprehensive review, analysis, and knowledge representation of binary classification performance measures/metrics. *SN Computer Science*, 4(1), 13.
- Cardoso, P. H. M., Moreno, L. Z., De Oliveira, C. H., Gomes, V. T. M., Silva, A. P. S., Barbosa, M. R. F., Sato, M. I. Z., Balian, S. C., & Moreno, A. M. (2021). Main bacterial species causing clinical disease in ornamental freshwater fish in Brazil. *Folia Microbiologica*, 66(2), 231–239.
- Das, S. K., & Mandal, A. (2022). Diversification in aquaculture resources and practices for smallholder farmers. In *Agriculture, Livestock Production and Aquaculture: Advances for Smallholder Farming Systems Volume 1* (pp. 263–286). Springer.
- Diallo, R., Edalo, C., & Awe, O. O. (2024). Machine learning evaluation of imbalanced health data: a comparative analysis of balanced accuracy, MCC, and F1 score. In *Practical Statistical Learning and Data Science Methods: Case Studies from LISA 2020 Global Network, USA* (pp. 283–312). Springer.
- Ergün, E. (2025). SwinFishNet: A Swin Transformer-based approach for automatic fish species classification using transfer learning. *PLoS One*, 20(5), e0322711.
- Ghnemat, R., Alodibat, S., & Abu Al-Haija, Q. (2023). Explainable artificial intelligence (XAI) for deep learning based medical imaging classification. *Journal of Imaging*, 9(9), 177.
- Gholizade, M., Soltanizadeh, H., Rahmanimanesh, M., & Sana, S. S. (2025). A review of recent advances and strategies in transfer learning. *International Journal of System Assurance Engineering and Management*, 1–40.

- Giudici, P., Rosciano, R. C., Schrader, J., & Kummerfeld, D.-M. (2025). A Multiclass ROC Curve. ArXiv Preprint ArXiv:2510.15670.
- Giuffrida, R., de Majo, C., Giuffrida, M., & Broadbent, I. D. (2025). FAIR data management practices to introduce circular economy in aquaculture: benefits, barriers and a preliminary roadmap. *International Journal of Data Science and Analytics*, 1–21.
- Guluwadi, S. (2024). Enhancing brain tumor detection in MRI images through explainable AI using Grad-CAM with Resnet 50. *BMC Medical Imaging*, 24(1), 1–19.
- Haddad, M. H., & Hassan Mohammed, F. (2025). A CONVOLUTIONAL NEURAL NETWORK APPROACH FOR PRECISION FISH DISEASE DETECTION. <https://doi.org/10.46121/pspc.53.2.23>
- Hariri, M., Avsar, E., & Aydın, A. (2025). LatentResNet: An Optimized Underwater Fish Classification Model with a Low Computational Cost. *Journal of Marine Science and Engineering*, 13(6), 1019.
- Hasan, N., Ibrahim, S., & Aqilah Azlan, A. (2022). Fish diseases detection using convolutional neural network (CNN). *International Journal of Nonlinear Analysis and Applications*, 13(1), 1977–1984.
- Huang, Y.-P., & Khabusi, S. P. (2023). A CNN-OSELM multi-layer fusion network with attention mechanism for fish disease recognition in aquaculture. *IEEE Access*, 11, 58729–58744.
- Ibrahim, A., Zayed, T., & Lafhaj, Z. (2024). Enhancing construction performance: A critical review of performance measurement practices at the project level. *Buildings*, 14(7), 1988.
- Isaac, S., Daniel, O., Grivin, M., Kyagaba, J. M., Lule, E., & Marvin, G. (2024). Explainable Machine Vision Techniques for Fish Disease Detection with Deep Transfer Learning. 2024 5th International Conference on Electronics and Sustainable Communication Systems (ICESC), 1218–1227. <https://doi.org/10.1109/ICESC60852.2024.10689742>
- Kalusivalingam, A. K., Sharma, A., Patel, N., & Singh, V. (2021). Enhancing diagnostic accuracy in medical imaging through convolutional neural networks and transfer learning algorithms. *International Journal of AI and ML*, 2(3).
- Liao, L., Li, H., Shang, W., & Ma, L. (2022). An empirical study of the impact of hyperparameter tuning and model optimization on the performance properties of deep neural networks. *ACM Transactions on Software Engineering and Methodology (TOSEM)*, 31(3), 1–40.
- MacAulay, S., Ellison, A. R., Kille, P., & Cable, J. (2022). Moving towards improved surveillance and earlier diagnosis of aquatic pathogens: From traditional methods to emerging technologies. *Reviews in Aquaculture*, 14(4), 1813–1829.
- Mamun, M. R. I., Rahman, U. S., Akter, T., & Azim, M. A. (2023). Fish Disease Detection using Deep Learning and Machine Learning. *International Journal of Computer Applications*, 975, 8887.
- Mandal, A., & Ghosh, A. R. (2024). Role of artificial intelligence (AI) in fish growth and health status monitoring: A review on sustainable aquaculture. *Aquaculture International*, 32(3), 2791–2820.
- Minh, D., Wang, H. X., Li, Y. F., & Nguyen, T. N. (2022). Explainable artificial intelligence: a comprehensive review. *Artificial Intelligence Review*, 55(5), 3503–3568.

- Mohanty, S., & Sahoo, P. K. (2025). Role of Environment in Aquatic Animal Health and Noninfectious Diseases in Finfish Aquaculture. In *Aquatic Animal Health Management* (pp. 475–505). Springer.
- Nishat, A. (2024). Regularization Frameworks for Overfitting Prevention in Language Model Fine-Tuning. *International Journal of Digital Innovation*, 5(1).
- Owusu-Adjei, M., Ben Hayfron-Acquah, J., Frimpong, T., & Abdul-Salaam, G. (2023). Imbalanced class distribution and performance evaluation metrics: A systematic review of prediction accuracy for determining model performance in healthcare systems. *PLOS Digital Health*, 2(11), e0000290.
- Rimmer, M. A., Larson, S., Lapong, I., Purnomo, A. H., Pong-Masak, P. R., Swanepoel, L., & Paul, N. A. (2021). Seaweed aquaculture in Indonesia contributes to social and economic aspects of livelihoods and community wellbeing. *Sustainability*, 13(19), 10946.
- Roscher, M. B., Allison, E. H., Mills, D. J., Eriksson, H., Hellebrandt, D., & Andrew, N. L. (2022). Sustainable development outcomes of livelihood diversification in small-scale fisheries. *Fish and Fisheries*, 23(4), 910–925.
- Shubham, S., Jain, N., Gupta, V., Mohan, S., Ariffin, M. M., & Ahmadian, A. (2023). Identify glomeruli in human kidney tissue images using a deep learning approach. *Soft Computing*, 27(5), 2705–2716. <https://doi.org/10.1007/s00500-021-06143-z>
- Sultana, M., Bhattacharya, S., Adhikari, N., Sengupta, D., & De, D. (2024). Artificial intelligence for sustainable ocean health. In *Artificial intelligence and edge computing for sustainable ocean health* (pp. 3–38). Springer.
- Suzuki, A. (2021). Rising importance of aquaculture in Asia: current status, issues, and recommendations. *Asian Development Outlook Update Background Paper*. Asian Development Bank, Manila.
- Szandała, T. (2023). Unlocking the black box of CNNs: Visualising the decision-making process with PRISM. *Information Sciences*, 642, 119162.
- Tang, M., Ting, K. C., & Rashidi, N. H. (2024). DenseNet201-based waste material classification using transfer learning approach. *Applied Mathematics and Computational Intelligence (AMCI)*, 13(2), 113–120.
- Teng, Q., Liu, Z., Song, Y., Han, K., & Lu, Y. (2022). A survey on the interpretability of deep learning in medical diagnosis. *Multimedia Systems*, 28(6), 2335–2355.
- Tezzo, X., Bush, S. R., Oosterveer, P., & Belton, B. (2021). Food system perspective on fisheries and aquaculture development in Asia. *Agriculture and Human Values*, 38(1), 73–90.
- Virginia, V. V, Mbanaso, U. M., Chaku, E. S., Clementina, I. O., & Aimufua, G. (2025). Deep learning and convolutional neural networks (CNNs). *GAS Journal of Engineering and Technology (GASJET)*, 2(11), 73–84.
- Wulandari, S. K., & Jasmir, J. (2024). Penggunaan Resnet-50 Untuk Deteksi Penyakit Ikan Air Tawar di Akuakultur Studi Kasus pada Akuakultur Asia Selatan. *Prosiding Seminar Nasional Bisnis, Teknologi Dan Kesehatan (SENABISTEKES)*, 1(1), 17–24.
- Yang, Y., Theisen, R., Hodgkinson, L., Gonzalez, J. E., Ramchandran, K., Martin, C. H., & Mahoney, M. W. (2023). Test accuracy vs. generalization gap: Model selection in nlp

without accessing training or testing data. Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, 3011–3021.

Zhang, C., Bengio, S., Hardt, M., Recht, B., & Vinyals, O. (2021). Understanding deep learning (still) requires rethinking generalization. *Communications of the ACM*, 64(3), 107–115.

Zhao, C. H., & Leong, W. Y. (2025). Optimization solutions and simple innovative solution research on ResNet50 model. *ASM Science Journal*, 20(1).