

PENGEMBANGAN SISTEM DETEKSI PENYAKIT IKAN NILA BERBASIS CITRA DIGITAL MENGGUNAKAN METODE DEEP LEARNING MOBILE NET V2 BERBASIS WEB

Siti Nurlaeli ¹, Rio Ferddinansya ², Akhfa Bagas Alfarizi ³, Dodik Ariyanto ⁴, Faldiena Marcelita ⁵

^{1,2,3} Teknologi Rekayasa Perangkat Lunak, Sekolah Vokasi IPB University

^{4,5} Teknologi Rekayasa Komputer, Sekolah Vokasi IPB University

Jl. Kumbang No.14, Kelurahan Babakan, Kecamatan Bogor Tengah, Kota Bogor, Jawa Barat 16128

2135_nurlaeli@apps.ipb.ac.id

ABSTRAK

Budidaya ikan nila di Indonesia merupakan sektor strategis yang sering terhambat oleh serangan penyakit, sehingga deteksi dini menjadi krusial bagi keberlanjutan usaha. Pemanfaatan *deep learning* dan *smart fishery* kini menawarkan peluang besar untuk otomatisasi diagnosis penyakit melalui pengenalan citra digital. Namun, pembudidaya sering menghadapi keterbatasan kemampuan identifikasi yang memicu keterlambatan penanganan, sementara penelitian sebelumnya masih terbatas pada penggunaan *dataset* umum yang kurang spesifik atau belum terintegrasi ke dalam sistem berbasis *web*. Penelitian ini bertujuan mengembangkan sistem deteksi penyakit ikan nila berbasis *Convolutional Neural Network* yang terintegrasi dalam platform *web-based system* untuk diagnosa yang cepat dan akurat. Pengembangan model menggunakan *dataset* lokal dan publik, *preprocessing* citra, serta arsitektur *MobileNetV2* untuk meningkatkan presisi klasifikasi. Hasil penelitian menunjukkan bahwa model *MobileNetV2* mencapai akurasi sebesar 97,18%, yang mampu memberikan diagnosis otomatis beserta rekomendasi penanganan secara efisien. Sistem ini berkontribusi nyata sebagai alat bantu bagi pembudidaya untuk meminimalisir risiko kegagalan panen dan mendukung produktivitas sektor perikanan.

Kata kunci : Deteksi penyakit, ikan nila, *deep learning*, CNN, *MobileNetV2*, citra digital

1. PENDAHULUAN

Budidaya ikan nila merupakan salah satu sektor perikanan air tawar yang memiliki nilai ekonomi tinggi di Indonesia. Namun, produktivitas budidaya seringkali terganggu oleh munculnya berbagai penyakit yang dapat menyebabkan penurunan kualitas ikan, peningkatan angka kematian, serta kerugian ekonomi yang signifikan. Permasalahan utama yang dihadapi pembudidaya, khususnya pemula, adalah keterbatasan kemampuan dalam mengidentifikasi jenis penyakit secara cepat dan akurat berdasarkan gejala visual yang muncul pada tubuh ikan. Kesalahan diagnosis dapat berakibat pada keterlambatan penanganan dan penyebaran penyakit.

Perkembangan teknologi pengolahan citra digital dan *deep learning* membuka peluang dalam pengembangan sistem deteksi penyakit ikan secara otomatis berbasis gambar. Beberapa penelitian menunjukkan bahwa pendekatan *Convolutional Neural Network* (CNN) mampu memberikan akurasi tinggi dalam klasifikasi penyakit ikan berbasis citra digital [1] [2].

Selain itu, penerapan *deep learning* dalam konsep *smart fishery* juga menunjukkan potensi integrasi sistem deteksi dengan teknologi berbasis kecerdasan buatan untuk mendukung pengambilan keputusan di bidang akuakultur [3].

Permasalahan utama yang dihadapi pembudidaya, khususnya pemula, adalah keterbatasan kemampuan dalam mengidentifikasi jenis penyakit secara cepat dan akurat berdasarkan gejala visual yang muncul pada tubuh ikan [4].

Kesalahan diagnosis dapat berakibat pada keterlambatan penanganan dan penyebaran penyakit 2.

Di sisi lain, penelitian lain masih memiliki keterbatasan, seperti fokus pada spesies selain ikan nila, penggunaan *dataset* umum yang tidak spesifik terhadap kondisi lapangan lokal, atau belum terintegrasi dalam sistem berbasis *web* yang mudah diakses oleh pembudidaya [5] [6].

Selain itu, beberapa sistem pakar berbasis aturan juga masih bergantung pada input gejala manual sehingga bersifat subjektif dan kurang optimal dalam mendeteksi penyakit berbasis visual [7].

Penelitian ini bertujuan untuk Mengembangkan model *deep learning* berbasis *Convolutional Neural Network* (CNN) dan *MobileNetV2* untuk klasifikasi penyakit ikan nila berbasis citra digital. Membandingkan performa kedua model dalam hal akurasi, loss, dan kemampuan generalisasi. Mengimplementasikan model terbaik ke dalam sistem berbasis web yang dapat digunakan untuk deteksi penyakit ikan secara otomatis. Menyediakan sistem yang dapat membantu pembudidaya ikan nila dalam melakukan diagnosis awal secara cepat, mudah, dan akurat.

Rencana penyelesaian masalah pada penelitian ini adalah mengembangkan sistem deteksi penyakit ikan nila berbasis web dengan memanfaatkan pendekatan *deep learning*. Sistem yang diusulkan diharapkan mampu membantu proses identifikasi penyakit ikan nila secara lebih cepat dan objektif melalui analisis citra digital. Untuk memperoleh model dengan performa terbaik, penelitian ini

menggunakan dua arsitektur deep learning, yaitu Convolutional Neural Network (CNN) dan MobileNetV2, yang kemudian dibandingkan berdasarkan hasil evaluasi kinerjanya. Melalui pendekatan tersebut, diharapkan sistem dapat menjadi alat bantu diagnosis awal yang mudah diakses oleh pembudidaya ikan nila.

2. TINJAUAN PUSTAKA

2.1. Penyakit Ikan Nila

Penyakit pada ikan nila (*Oreochromis niloticus*) merupakan salah satu kendala utama yang menyebabkan kerugian ekonomi secara masif dan ancaman terhadap ketahanan pangan global dalam sektor akuakultur [8].

Berbagai patogen infeksius yang umum menyerang ikan nila terdiri dari kelompok bakteri, virus, jamur, dan parasit [8].

Infeksi bakteri yang sangat merugikan antara lain *Streptococcosis* yang dipicu oleh bakteri *Streptococcus agalactiae* dan *S. iniae*, yang menyerang secara sistemik pada berbagai sistem budidaya [9].

Selain itu, terdapat penyakit *Motile Aeromonad Septicemia* (MAS) akibat *Aeromonas hydrophila* yang ditandai dengan borok kulit, pendarahan, dan nekrosis organ dalam [10], serta penyakit *Columnaris* oleh *Flavobacterium columnare* yang memunculkan bercak putih hingga xam kuning pada kulit dan insang [11].

Selain penyakit bakteri, infeksi jamur seperti *Saprolegniasis* juga sering menyerang ikan nila, terutama pada kondisi kualitas air yang buruk atau ikan mengalami luka fisik. Penyakit ini disebabkan oleh jamur *Saprolegnia spp.* yang ditandai dengan munculnya lapisan menyerupai kapas berwarna putih pada permukaan tubuh ikan [12].

Adapun penyakit parasit seperti *WhiteSpot* atau *Ichthyophthiriasis* disebabkan oleh protozoa *Ichthyophthirius multifiliis* yang memunculkan bintik-bintik putih pada tubuh dan insang ikan sehingga mengganggu sistem pernapasan ikan [13].

Berbagai penyakit tersebut memiliki karakteristik visual yang berbeda-beda sehingga dapat dimanfaatkan sebagai dasar dalam pengembangan sistem deteksi penyakit ikan berbasis citra digital.

2.1. Pengolahan Citra Digital untuk Deteksi Penyakit

Pengolahan citra digital merupakan tahapan krusial dalam sistem deteksi penyakit berbasis visi komputer yang bertujuan memastikan kualitas dan konsistensi data sebelum dianalisis oleh algoritma *machine learning* [2].

Dalam konteks patologi ikan, tahapan pra pemrosesan citra difokuskan untuk memperbaiki segmentasi, deteksi, dan pengenalan fitur visual dengan melakukan standarisasi resolusi (*resizing*) serta normalisasi nilai piksel (*rescaling*) [2].

Modifikasi kualitas citra seperti penghilangan gangguan (*denoising*), penajaman tepi (*sharpening*), dan penghalusan (*smoothing*) diimplementasikan agar detail klinis seperti lesi dapat terlihat jelas tanpa distorsi [2].

Selanjutnya, teknik augmentasi citra digunakan untuk mereplikasi berbagai kondisi nyata lingkungan akuakultur dan memperkaya variasi data latih [14].

Transformasi geometris dan fotometrik (seperti kecerahan dan kontras), deformasi elastis untuk mensimulasikan gerakan ikan, serta pembentukan citra sintesis menggunakan *Generative Adversarial Networks* (GANs) dimanfaatkan secara efektif dalam mencegah *overfitting* pada model buatan [14].

Metode segmentasi tingkat lanjut seperti DeepLabv3+, U-Net, dan Mask R-CNN juga diterapkan untuk mengisolasi penanda atau gejala spesifik penyakit pada organ ikan [14].

2.2. Deep Learning & CNN dalam Akuakultur

Deep learning, secara khusus arsitektur *Convolutional Neural Network* (CNN), telah membuktikan diri sebagai fondasi teknologi terdepan untuk menyelesaikan masalah pengenalan pola visual yang kompleks dalam bidang akuakultur [8].

Konsep kerja CNN pada deteksi penyakit ikan adalah mengekstraksi fitur spasial tingkat tinggi dari citra menggunakan lapisan konvolusional kaskade dan fungsi aktivasi *Rectified Linear Unit* (ReLU) yang memberikan non-linearitas [2].

Output dari ekstraksi ini kemudian melewati lapisan *pooling* (seperti *max-pooling*) untuk reduksi dimensi fitur, diratakan melalui lapisan *flattening*, lalu masuk ke dalam dense layer untuk diubah menjadi probabilitas klasifikasi akhir [2].

CNN meniadakan perlunya proses ekstraksi dan interpretasi manual, dengan kemampuannya mengidentifikasi deviasi morfologis secara adaptif [2].

Implementasi CNN pada deteksi penyakit ikan menggunakan model spesifik seperti *EfficientNet-B4*, *ResNet-50*, *Inception-v4*, hingga VGG-16 terbukti mencapai akurasi lebih dari 90% pada pengenalan penyakit seperti kebusukan insang, lesi ekor, dan patogen lainnya [14].

2.3. Implementasi Aplikasi Berbasis Web untuk Diagnosa Penyakit Ikan

Implementasi aplikasi berbasis web dirancang untuk membawa teknologi model deteksi *deep learning* langsung ke tangan pembudidaya ikan secara efisien tanpa kewajiban menginstal perangkat keras lokal yang berat [14].

Aplikasi diagnosa web yang inovatif bekerja secara independen memadukan *frontend* (seperti *React*, *HTML*, atau *JavaScript*) sebagai antarmuka yang ramah pengguna dan *backend* (seperti *Node.js* atau server bertenaga GPU) yang menampung model *machine learning* seperti *TensorFlow* [15].

Sebuah implementasi dari platform seperti *Nile Tilapia Disease Classification Chatbot* (NTD-CC)

memungkinkan penggunaannya untuk mengunggah citra ikan statis atau merekam gambar langsung (*live camera*), lalu platform mengirimkannya ke sisi server untuk inferensi jaringan saraf tiruan secara *real-time* [14].

Implementasi infrastruktur ini tidak hanya meminimalisasi siklus waktu tunggu konfirmasi penyakit dari metode diagnostik konvensional secara drastis, tetapi juga mengintegrasikan panduan klinis instan [15].

2.4. Sistem Konsultasi Berbasis AI di Akuakultur

Sistem konsultasi berbasis kecerdasan buatan (AI) dikembangkan untuk mereduksi kesenjangan antara ahli patologi ikan dengan petani budidaya melalui diseminasi pengetahuan spesifik yang sangat interaktif dan sadar-konteks [16].

Secara konseptual, sistem konsultasi seperti "AgriSaathi" memanfaatkan kekuatan *Large Language Models* (LLMs) dengan kerangka kerja *Retrieval-Augmented Generation* (RAG) dan AI multimodal [16]. Alih-alih hanya berpegang pada pengetahuan prapelatihan generik yang berisiko mengalami halusinasi informasi, modul RAG bertugas mencari data secara spesifik di basis literatur budidaya ilmiah maupun direktori penyakit [16].

Respons LLM digabungkan bersama interpretasi visual oleh komputer (*computer vision*) saat pembudidaya memberikan masukan citra ikan yang terjangkit gejala, kemudian pemrosesan *speech-to-text* memfasilitasi interaksi pengguna menggunakan suara dan bahasa lokal [16].

Model AI proaktif ini kemudian menyajikan laporan panduan yang akurat, terverifikasi dari sisi pandang saintifik akuakultur, serta dapat dipertanggungjawabkan dalam membantu memandu intervensi penyakit [16].

2.5. Arsitektur MobileNetV2

MobileNetV2 adalah arsitektur yang dirancang untuk mengoptimalkan operasi konvolusional guna mengurangi parameter komputasi tanpa mengorbankan kemampuan ekstraksi fiturnya [17].

Secara teknis, model ini bekerja menggunakan serangkaian blok *inverted residual* dan *depthwise separable convolutions* yang beroperasi secara berurutan [17].

Prosesnya dimulai dengan konvolusi ekspansi 1×1 untuk memperluas dimensi saluran dari ruang yang sempit (*bottleneck*) menjadi lebih luas, dilanjutkan dengan konvolusi *depthwise* 3×3 yang melakukan pemrosesan spasial secara independen pada setiap saluran, dan diakhiri oleh konvolusi proyeksi 1×1 untuk mereduksi kembali dimensi saluran ke ukuran *bottleneck* aslinya [17].

Arsitektur ini juga menerapkan koneksi residual (*shortcut*) ketika dimensi spasial serta jumlah saluran input dan output memiliki nilai yang sama, sehingga model mampu mempertahankan informasi spasial

yang mendetail (*fine-grained*) dengan sangat efisien serta menghasilkan waktu inferensi yang rendah [17].

Dalam konteks deteksi dan klasifikasi gambar penyakit ikan, *MobileNetV2* memiliki relevansi dan keunggulan strategis sebagai arsitektur yang hemat sumber daya. Model ini telah terbukti sangat kapabel dalam menangani tantangan klasifikasi objek, dengan pencapaian akurasi pengenalan visual yang tinggi [8].

Sifat modelnya yang *lightweight* membuat *MobileNetV2* sangat cocok digunakan dalam pengembangan aplikasi diagnostik berbasis web atau seluler (IoT) guna menjangkau para pembudidaya akuakultur di lokasi terpencil dengan fasilitas perangkat keras komputasi yang terbatas [8].

2.6. Penelitian Terdahulu

Berdasarkan studi terdahulu, model seperti *Random Forest*, *K-Means Clustering*, *SVM*, maupun modul pengolahan gambar konvensional terbatas pada nilai akurasi sekitar 87-94% dalam mengenali penyakit kompleks [14].

Adapun kemajuan mutakhir kini mempekerjakan *Adaptive Artificial Multiple Intelligence Fusion System* (A-AMIFS) yang mampu menembus akurasi antara 98,26% hingga mencapai 99,71% dan nilai presisi tinggi [18].

Sistem ini memiliki keunggulan komprehensif lewat penggabungan algoritma optimasi untuk augmentasi data dan segmentasi gambar yang canggih yang selanjutnya difusikan dengan variasi arsitektur CNN tangguh secara dinamis [14].

Namun, kekurangan sekaligus tantangan pada sistem *state-of-the-art* ini masih terletak pada besarnya beban kompleksitas waktu pelatihan model secara komputasi serta kerentanan misklasifikasi dalam membedakan karakteristik kelas infeksi penyakit yang secara visual amat serupa (seperti penyakit insang bakteri dengan penyakit bakteri merah) [8].

Untuk mencapai adopsi ke depan, pendekatan berbasis kompresi model serta asimilasi sistem *lightweight* di tingkat *edge computing* dipandang sebagai prospek kemajuan paling relevan [8].

3. METODE PENELITIAN

3.1. Jenis Penelitian

Penelitian ini merupakan penelitian eksperimental yang berfokus pada pengembangan sistem deteksi penyakit ikan nila berbasis citra digital menggunakan pendekatan *deep learning*. Metode yang digunakan dalam penelitian ini adalah *Convolutional Neural Network* (CNN) dan arsitektur *MobileNetV2* untuk melakukan klasifikasi kondisi ikan berdasarkan gambar.

Penelitian dilakukan melalui beberapa tahapan, yaitu pengumpulan data citra ikan nila, *preprocessing* data, perancangan dan pelatihan model, serta evaluasi performa model. Selain itu, model yang telah dikembangkan diimplementasikan ke dalam sistem berbasis web untuk memudahkan pengguna dalam melakukan deteksi penyakit secara langsung.

Pendekatan ini bertujuan untuk menghasilkan sistem yang mampu memberikan hasil klasifikasi penyakit secara akurat serta dapat diakses dengan mudah oleh pembudidaya, khususnya petani pemula.

3.2. Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan yang terstruktur mulai dari pengumpulan data hingga implementasi sistem berbasis *web*. Secara umum, alur penelitian ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

Diagram pada Gambar 1 menunjukkan tahapan penelitian yang dimulai dari proses pengumpulan data citra ikan nila, dilanjutkan dengan tahap preprocessing data, perancangan dan pelatihan model menggunakan *Convolutional Neural Network* (CNN) dan *MobileNetV2*, serta evaluasi performa model. Selanjutnya, model terbaik diimplementasikan ke dalam sistem berbasis *web* untuk menghasilkan output berupa deteksi penyakit dan rekomendasi penanganan.

3.3. Pengumpulan Data

Data yang digunakan dalam penelitian ini berupa citra ikan nila yang diklasifikasikan ke dalam beberapa kategori, yaitu ikan sehat dan ikan yang terindikasi penyakit. Dataset diperoleh dari dua sumber, yaitu dataset publik yang tersedia pada platform Kaggle serta dataset hasil dokumentasi lapangan yang diambil secara mandiri.

Pengambilan data lapangan dilakukan untuk menyesuaikan kondisi lingkungan budidaya yang sebenarnya serta menambah variasi citra agar model memiliki kemampuan generalisasi yang lebih baik. Setiap citra yang diperoleh kemudian melalui proses seleksi dan pelabelan (*labeling*) sesuai dengan kondisi kesehatan ikan.

Proses pelabelan dilakukan secara manual berdasarkan karakteristik visual gejala penyakit yang terlihat pada tubuh ikan. Data yang telah diberi label selanjutnya digunakan dalam proses *supervised learning* pada model *Convolutional Neural Network* (CNN).

3.4. Preprocessing Data

Tahap pra-pemrosesan data dilakukan untuk menyeragamkan format citra dan meningkatkan kualitas data agar model lebih robust terhadap berbagai kondisi input. Tahapan preprocessing dalam penelitian ini meliputi:

a. Resizing (Pengubahan Ukuran)

Seluruh citra diubah ukurannya menjadi 224×224 piksel. Ukuran ini dipilih untuk menyesuaikan dengan kebutuhan input arsitektur *MobileNetV2*

serta menjaga keseimbangan antara detail citra dan efisiensi komputasi.

b. Rescaling (Normalisasi)

Nilai piksel citra yang semula berada pada rentang 0–255 diubah menjadi rentang 0–1 dengan cara membagi setiap nilai piksel dengan 255. Proses ini bertujuan untuk membantu model dalam proses pembelajaran agar lebih stabil.

c. Augmentasi Citra (*Image Augmentation*)


Augmentasi citra dilakukan untuk meningkatkan variasi data serta mengurangi risiko *overfitting* pada model. Teknik augmentasi yang diterapkan dalam penelitian ini meliputi rotasi hingga 40 derajat, pergeseran secara horizontal dan vertikal, perbesaran (*zoom*) citra, serta pembalikan citra secara horizontal (*horizontal flip*).

d. Pembagian Data (*Data Splitting*)

Dataset dibagi menjadi tiga bagian, yaitu data pelatihan (*training set*), validasi (*validation set*), dan pengujian (*test set*). Pembagian ini dilakukan untuk memastikan proses evaluasi model berjalan secara objektif.

3.5. Perancangan Model CNN dan MobileNetV2

Pada tahap ini dilakukan perancangan model klasifikasi citra menggunakan pendekatan *Convolutional Neural Network* (CNN) dan *MobileNetV2*. Model CNN yang digunakan merupakan arsitektur sederhana (*baseline CNN*) yang terdiri dari beberapa lapisan *convolutional*, *max pooling*, dan *fully connected layer* untuk mengekstraksi fitur visual dari citra ikan nila. Selain itu, digunakan juga model *MobileNetV2* berbasis *transfer learning* dengan memanfaatkan bobot *pre-trained* dari *ImageNet* untuk meningkatkan kemampuan ekstraksi fitur. Kedua model dirancang untuk melakukan klasifikasi multi-kelas berdasarkan jenis penyakit ikan nila, dengan input citra berukuran 224×224 piksel dan output berupa probabilitas dari masing-masing kelas penyakit. Arsitektur model CNN yang digunakan dalam penelitian ini ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur Model CNN

Diagram pada Gambar 2 menunjukkan alur proses pada model CNN yang dimulai dari input citra, kemudian diproses melalui beberapa lapisan *convolutional* untuk mengekstraksi fitur, dilanjutkan dengan *pooling layer* untuk reduksi dimensi, dan diakhiri dengan *fully connected layer* untuk menghasilkan output klasifikasi. Model ini digunakan sebagai pembanding terhadap *MobileNetV2* dalam mengevaluasi performa klasifikasi penyakit ikan nila.

3.6. Pelatihan Model

Pelatihan model dilakukan menggunakan dataset citra ikan nila yang telah melalui tahap preprocessing. Proses pelatihan dilakukan pada dua model, yaitu *Convolutional Neural Network* (CNN) dan *MobileNetV2*.

Pada tahap ini, data pelatihan (*training set*) digunakan untuk melatih model dalam mengenali pola citra, sedangkan data validasi (*validation set*) digunakan untuk memantau performa model selama proses pelatihan. Proses pelatihan dilakukan selama sejumlah epoch hingga model mencapai kondisi konvergen.

Model *MobileNetV2* dilatih menggunakan pendekatan *transfer learning*, dengan memanfaatkan bobot awal (*pre-trained*) dari *ImageNet*. Sementara itu, model CNN dilatih dari awal (*from scratch*). Hasil pelatihan kemudian digunakan untuk proses evaluasi guna menentukan model dengan performa terbaik.

3.7. Evaluasi Model

Evaluasi model dilakukan untuk mengukur performa klasifikasi model menggunakan data uji (*test data*). Pada penelitian ini, evaluasi dilakukan menggunakan beberapa metrik, yaitu *accuracy* dan *loss*. Nilai *accuracy* digunakan untuk mengukur tingkat ketepatan model dalam melakukan klasifikasi, sedangkan *loss* digunakan untuk mengetahui tingkat kesalahan prediksi model selama proses pelatihan.

Selain itu, dilakukan analisis visual menggunakan grafik *training* dan *validation* untuk melihat perkembangan performa model selama proses pelatihan. Evaluasi lebih lanjut juga dilakukan menggunakan *confusion matrix* untuk mengetahui kemampuan model dalam membedakan setiap kelas penyakit ikan nila secara lebih rinci.

3.8. Implementasi Sistem

Implementasi sistem dilakukan dengan mengintegrasikan model *machine learning* ke dalam aplikasi berbasis web. Sistem dirancang menggunakan arsitektur *frontend* dan *backend*, di mana *frontend* berfungsi sebagai antarmuka pengguna untuk melakukan unggah gambar ikan nila, sedangkan *backend* bertugas memproses citra dan menjalankan model klasifikasi penyakit.


Model yang telah dilatih diintegrasikan ke dalam sistem untuk melakukan proses inferensi secara *real-time*. Selain itu, sistem juga dilengkapi dengan fitur *chatbot AI* yang digunakan untuk memberikan informasi tambahan terkait penyakit ikan nila berdasarkan hasil deteksi model. Implementasi sistem ini bertujuan untuk mempermudah pengguna, khususnya pembudidaya ikan nila pemula, dalam melakukan diagnosis awal penyakit secara mandiri melalui platform berbasis web.

4. HASIL DAN PEMBAHASAN

4.1. Analisis Dataset dan Distribusi Kelas

Penelitian ini menggunakan dataset citra ikan nila yang terdiri dari kategori, yaitu *Columnaris*, *Healthy*, *MAS*, *Saprolegniasis*, dan *Streptococcus*. Dataset diperoleh dari hasil penggabungan beberapa sumber data, yang kemudian dilakukan penyesuaian label (*label mapping*) serta pembersihan data (*data cleaning*) untuk menghapus citra yang rusak atau tidak dapat dibaca.

Selanjutnya, dataset dibagi menjadi data pelatihan (*training*), validasi (*validation*), dan pengujian (*testing*) untuk memastikan evaluasi model dilakukan secara objektif. Distribusi jumlah data pada setiap kelas ditunjukkan pada Gambar 6.



Gambar 3. Distribusi Data Training

Berdasarkan Gambar 3, jumlah sampel data pada setiap kelas tidak sepenuhnya sama rata, di mana kelas MAS memiliki jumlah data terbanyak, sedangkan kelas *Columnaris* memiliki jumlah sampel yang paling sedikit. Meskipun terdapat variasi jumlah data antar kelas, perbedaannya tidak terlalu signifikan sehingga dataset masih dapat dikategorikan sebagai *semi-balanced*. Kondisi tersebut menunjukkan bahwa distribusi data masih cukup baik untuk digunakan dalam proses pelatihan model klasifikasi. Dengan distribusi data yang tersedia, model diharapkan mampu mempelajari karakteristik fitur visual dari masing-masing jenis penyakit ikan nila secara optimal dan menghasilkan performa klasifikasi yang baik.

4.2. Hasil Pelatihan dan Pengujian Model

Eksperimen dilakukan dengan membandingkan performa model CNN dan *MobileNetV2* pada tahap pelatihan (*training*) dan pengujian (*testing*). Evaluasi dilakukan menggunakan metrik *accuracy* dan *loss* untuk mengetahui kemampuan model dalam melakukan klasifikasi penyakit ikan nila.

Tabel 1. Hasil Pelatihan Model

Arsitektur Model	Training Accuracy	Training Loss
CNN	82.63%	0.5280
MobileNetV2	98.36%	0.0593

Berdasarkan Tabel 1, model *MobileNetV2* menunjukkan performa pelatihan yang lebih baik dibandingkan CNN. Hal ini ditunjukkan oleh nilai *accuracy* yang lebih tinggi serta nilai *loss* yang lebih rendah. Penggunaan metode *transfer learning* pada *MobileNetV2* membantu model dalam mengekstraksi fitur visual citra penyakit ikan nila secara lebih efektif.


Tabel 2. Hasil Pengujian Model

Arsitektur Model	Test Accuracy	Test Loss
CNN	80.46%	0.5652
MobileNetV2	95.69%	0.1638

Berdasarkan Tabel 2, model *MobileNetV2* kembali menunjukkan performa terbaik pada data pengujian dengan nilai *accuracy* sebesar 95.69%, lebih tinggi dibandingkan CNN yang memperoleh 80.46%. Selain itu, nilai *loss* pada *MobileNetV2* juga lebih rendah, yang menunjukkan tingkat kesalahan prediksi yang lebih kecil. Hasil ini menunjukkan bahwa model *MobileNetV2* memiliki kemampuan generalisasi yang lebih baik terhadap data baru dibandingkan model CNN sederhana.


4.3. Analisis Kurva Pembelajaran

Analisis kurva pembelajaran dilakukan untuk mengamati perkembangan performa model selama proses pelatihan menggunakan data *training* dan *validation*.



Gambar 4. Visualisasi Evaluasi CNN

Gambar 4 menunjukkan bahwa model CNN mengalami peningkatan nilai *accuracy* dan penurunan nilai *loss* secara bertahap selama proses pelatihan. Nilai *accuracy* pada data *training* mencapai sekitar 84%, sedangkan pada data *validation* mencapai sekitar 78%–80%. Kurva *validation* secara umum mengikuti pola kurva *training*, meskipun terdapat beberapa fluktuasi pada epoch tertentu, terutama pada kurva *loss*. Fluktuasi tersebut menunjukkan bahwa model masih mengalami variasi performa selama proses pembelajaran. Namun, selisih antara kurva *training* dan *validation* yang relatif kecil menunjukkan bahwa model CNN masih memiliki kemampuan generalisasi yang cukup baik dan tidak mengalami *overfitting* yang signifikan.




Gambar 5. Visualisasi Evaluasi MobileNetV2

Gambar 5 menunjukkan bahwa model *MobileNetV2* memiliki performa dan stabilitas yang lebih baik dibandingkan model CNN sederhana. Nilai *accuracy* meningkat secara signifikan pada epoch awal dan mencapai kondisi stabil pada kisaran 95%–97% untuk data *training* serta sekitar 94%–95% pada data *validation*. Kurva *training* dan *validation* terlihat relatif berdekatan, yang menandakan bahwa model mampu mempelajari pola data secara konsisten. Selain itu, nilai *loss* menurun secara tajam pada awal pelatihan dan terus menurun secara stabil hingga akhir epoch tanpa fluktuasi yang berarti.

Berdasarkan hasil visualisasi kedua model tersebut, *MobileNetV2* menunjukkan performa yang lebih baik dibandingkan CNN, baik dari segi stabilitas kurva maupun kecepatan konvergensi. Hal ini dipengaruhi oleh penerapan metode *transfer learning* yang memanfaatkan *pre-trained weights*, sehingga model memiliki kemampuan ekstraksi fitur yang lebih optimal. Secara umum, kedua model tidak menunjukkan indikasi *overfitting* maupun *underfitting* yang signifikan karena pola kurva *training* dan *validation* relatif sejalan. Dengan demikian, model yang dikembangkan memiliki kemampuan generalisasi yang baik dalam mengklasifikasikan penyakit ikan nila pada data baru.

4.4. Evaluasi Model Menggunakan Confusion Matrix

Untuk mengukur performa klasifikasi secara rinci pada data pengujian, dilakukan analisis menggunakan *confusion matrix* dan *classification report* pada model *MobileNetV2*.



Gambar 6. Confusion Matrix dan Classification Report Model MobileNetV2


Berdasarkan Gambar 6, model mampu mengklasifikasikan sebagian besar citra pengujian dengan sangat baik, terlihat dari dominasi nilai yang tinggi pada diagonal utama matriks. Kelas *Saprolegniasis* menunjukkan hasil tertinggi dengan 86 prediksi benar dari 86 data uji (*recall* 1.00), diikuti kelas MAS (86/90) yang meraih *precision* sempurna 1.00, kelas *Healthy* (79/81), dan *Columnaris* (55/59).

Meskipun demikian, masih terdapat sedikit kesalahan klasifikasi, terutama pada kelas *Streptococcus* di mana terdapat 5 data aktual yang salah terprediksi sebagai *Columnaris* dan 2 data sebagai *Healthy*. Hal ini disebabkan oleh adanya kemiripan visual pada karakteristik klinis luka atau bercak pada kulit ikan yang ditimbulkan oleh infeksi bakteri tersebut.

Secara keseluruhan, hasil ini diperkuat oleh nilai *classification report* yang menunjukkan tingkat akurasi total model mencapai 96% dari keseluruhan 394 data pengujian. Nilai rata-rata (*macro & weighted avg*) untuk metrik *precision*, *recall*, dan *f1-score* juga konsisten berada di angka 0.95 hingga 0.96. Hasil ini membuktikan bahwa model *MobileNetV2* sangat andal dan memiliki kemampuan generalisasi yang tinggi untuk mendiagnosis penyakit ikan nila.

4.5. Implementasi pada Antarmuka Web

Model terbaik yang diperoleh dari penelitian ini, yaitu *MobileNetV2*, telah berhasil diintegrasikan ke dalam sistem aplikasi berbasis web bernama *NilaCare.AI*. Platform ini dirancang untuk memudahkan para pembudidaya ikan nila dalam melakukan diagnosis awal kesehatan komoditas secara mandiri, otomatis, dan *real-time*. Antarmuka pengguna (*user interface*) pada halaman utama fitur deteksi ditunjukkan pada Gambar 7.



Gambar 7. Antarmuka Fitur Prediksi Penyakit *NilaCare.AI*

Sistem menyediakan alur kerja yang intuitif bagi pengguna. Pembudidaya cukup mengunggah citra ikan nila yang terindikasi sakit melalui tombol yang tersedia pada halaman web, kemudian menekan tombol "Prediksi Sekarang". Selanjutnya, model *MobileNetV2* yang berada di sisi *backend* akan mengekstraksi fitur visual citra tersebut untuk melakukan inferensi klasifikasi penyakit. Seperti yang

diilustrasikan pada Gambar 7, saat mendeteksi sampel citra ikan nila dengan gejala klinis mata menonjol (*exophthalmia*), sistem berhasil mengidentifikasinya sebagai penyakit *Streptococcus* dengan tingkat kepercayaan (*confidence score*) yang sangat tinggi, yaitu mencapai 94.36%. Hal ini membuktikan model dapat berjalan dengan responsif dan akurat pada lingkungan aplikasi nyata.

Selain fitur deteksi berbasis gambar, antarmuka *NilaCare.AI* juga dilengkapi dengan fitur interaktif penunjang berupa asisten virtual cerdas berbasis teks, seperti yang ditunjukkan pada Gambar 8.



Gambar 8. Fitur Chat Asisten AI *NilaCare.AI* untuk Konsultasi Gejala

Fitur Chat Asisten *NilaCare.AI* berfungsi sebagai media konsultasi lanjutan bagi pengguna terkait gejala, pencegahan, dan penanganan penyakit ikan nila. Berdasarkan Gambar 8, *chatbot* AI mampu memberikan respons yang sesuai dengan hasil prediksi model, seperti mengidentifikasi gejala mata menonjol yang berkaitan dengan penyakit *Streptococcus* beserta informasi gejala pendukung lainnya. Integrasi antara fitur deteksi berbasis citra dan *chatbot* AI menghasilkan sistem diagnosis awal yang lebih interaktif dan mudah digunakan oleh pembudidaya ikan nila, khususnya pemula.

Secara keseluruhan, integrasi antara fitur deteksi berbasis gambar *MobileNetV2* dan fitur edukasi berbasis *chatbot* AI pada platform *NilaCare.AI* menghasilkan sebuah sistem pelaporan dan diagnosis mandiri yang utuh. Desain antarmuka yang bersih dan ramah pengguna memastikan sistem ini dapat dioperasikan dengan mudah oleh pembudidaya ikan nila pemula sekalipun tanpa memerlukan keahlian teknis yang rumit.

4.6. Pengujian Aplikasi

Pengujian aplikasi dilakukan untuk memastikan bahwa sistem *NilaCare.AI* dapat berjalan sesuai dengan fungsi yang dirancang. Pengujian dilakukan menggunakan metode *black box testing* dengan menguji fitur utama seperti unggah gambar, prediksi penyakit, tampilan *confidence score*, validasi file, serta fitur *chatbot* AI. Selain itu, dilakukan pengujian non-fungsional untuk menilai responsivitas tampilan, kecepatan proses prediksi, kemudahan penggunaan, dan kemampuan sistem dalam menangani input yang

tidak sesuai. Hasil pengujian menunjukkan bahwa fitur utama pada website dapat berjalan dengan baik dan sistem mampu memberikan hasil deteksi penyakit ikan nila secara otomatis melalui unggahan gambar.

Tabel 3. Hasil Pengujian Fungsional

No	Fitur	Skenario Pengujian	Status
1	Upload Gambar	Mengunggah gambar ikan nila	PASS
2	Prediksi Penyakit	Menekan tombol prediksi	PASS
3	Confidence Score	Prediksi berhasil dilakukan	PASS
4	Validasi File	Mengunggah file selain gambar	PASS
5	Chatbot AI	Mengirim pertanyaan terkait penyakit ikan nila	PASS
6	Navigasi Halaman	Berpindah antar halaman website	PASS
7	Responsivitas Form	Mengakses fitur upload pada perangkat berbeda	PASS

Berdasarkan Tabel 3, seluruh fitur utama pada aplikasi NilaCare.AI berhasil berjalan sesuai dengan fungsi yang dirancang. Fitur unggah gambar, prediksi penyakit, confidence score, chatbot AI, serta navigasi halaman memperoleh status PASS, sehingga sistem dapat digunakan dengan baik oleh pengguna.

Tabel 4. Hasil Pengujian Non-Fungsional

No	Aspek	Skenario Pengujian	Status
1	Responsivitas	Website dibuka di laptop dan HP	PASS
2	Kecepatan Prediksi	Upload gambar dan klik prediksi	PASS
3	Kemudahan Penggunaan	Pengguna mencoba fitur tanpa arahan teknis	PASS
4	Error Handling	Upload gambar buram / bukan ikan	PASS
5	Kompatibilitas Browser	Dibuka di Chrome/Edge	PASS

Berdasarkan Tabel 4, aplikasi NilaCare.AI menunjukkan performa yang baik dari aspek responsivitas, kecepatan prediksi, kemudahan penggunaan, penanganan kesalahan, dan kompatibilitas browser. Seluruh aspek yang diuji memperoleh status PASS, sehingga aplikasi dinilai mampu memberikan pengalaman penggunaan yang baik dan stabil.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa metode *Deep Learning* menggunakan arsitektur *Convolutional Neural Network* (CNN) dan *MobileNetV2* mampu diterapkan untuk mendeteksi penyakit ikan nila berbasis citra digital. Hasil pengujian menunjukkan bahwa model *MobileNetV2* memiliki performa yang

lebih baik dibandingkan CNN sederhana dengan nilai akurasi pengujian sebesar 95.69%, sedangkan model CNN memperoleh akurasi sebesar 80.46%. Selain itu, sistem berhasil diimplementasikan ke dalam aplikasi berbasis *web* yang memungkinkan pengguna melakukan deteksi penyakit ikan nila secara otomatis melalui unggahan gambar. Sistem juga dilengkapi fitur *chatbot* AI untuk membantu pengguna memperoleh informasi terkait penanganan dan pencegahan penyakit ikan nila.

Dengan demikian, sistem yang dikembangkan dapat menjadi solusi praktis untuk membantu pembudidaya ikan nila, khususnya pemula, dalam melakukan diagnosis awal penyakit secara mandiri. Untuk pengembangan penelitian selanjutnya, disarankan melakukan penambahan jumlah dan variasi dataset pada setiap kelas penyakit guna meningkatkan performa model dan mengurangi tingkat misklasifikasi. Selain itu, penelitian selanjutnya juga dapat menambahkan jenis penyakit lain serta mengembangkan fitur konsultasi yang lebih interaktif agar sistem memiliki cakupan diagnosis yang lebih luas dan komprehensif.

DAFTAR PUSTAKA

- [1] A A AlZubi, "Convolutional neural network modelling and image analysis techniques for the detection of fish diseases," *Indian J. Geo-Mar. Sci.*, vol. 53, no. 07, 2024, doi: 10.56042/ijms.v53i07.11740.
- [2] Dr. Mihaira H. Haddad dan Fatima Hassan Mohammed, "A Convolutional Neural Network Approach for Precision Fish Disease Detection," *Power Syst. Prot. Control*, vol. 53, no. 2, hlm. 1018–1033, Sep 2024, doi: 10.70082/esiculture.vi.1234.
- [3] R. Aryanti dan A. P. W. Wibowo, "Building a fish disease detection application based on Smart Fishery with Image Processing and Deep Learning," *Brill. Res. Artif. Intell.*, vol. 5, no. 1, hlm. 66–73, Apr 2025, doi: 10.47709/brilliance.v5i1.5719.
- [4] F. Rachman, M. Akbar, dan E. Putera, "FISH DISEASE DETECTION OF EPIZOOTIC ULCERATIVE SYNDROME USING DEEP LEARNING IMAGE PROCESSING TECHNIQUE," dalam *international Conference on Fisheries and Aquaculture*, The International Institute of Knowledge Management, Jan 2023, hlm. 23–34. doi: 10.17501/23861282.2023.8102.
- [5] I. A. C. Koten dan T. A. Setyarini, "SISTEM PAKAR DETEKSI PENYAKIT PADA IKAN NILA DENGAN METODE NAIVE BAYES CLASSIFIER," vol. 9, no. 3, 2025.
- [6] C. Z. Pratiwi, S. Jayanti, R. A. Subiantoro, dan B. W. Ziliwu, "Sistem Deteksi Penyakit Ikan Koi Menggunakan Metode YOLOv5," *Telekomun. Elektron. Komputasi Dan Kontrol*, vol. 11, no. 3, 2025, doi: <https://doi.org/10.15575/telka.v11n3.302-314>.

- [7] A. Shafira Salma, A. Burhanuddin, dan D. Fransisca Chika, "Sistem Pakar dalam Identifikasi Penyakit Pada Ikan Nila dengan Menggunakan Metode Forward Chaining dan Certainty Factor," *Smart Comp Jurnalnya Orang Pint. Komput.*, vol. 11, no. 3, Jul 2022, doi: 10.30591/smartcomp.v11i3.3788.
- [8] H. Tamut, R. Ghosh, K. Gosh, dan M. A. S. Siddique, "Enhancing Disease Detection in the Aquaculture Sector Using Convolutional Neural Networks Analysis," *Aquac. J.*, vol. 5, no. 1, hlm. 6, Mar 2025, doi: 10.3390/aquacj5010006.
- [9] F. S. Legario, C. H. Choresca, J. F. Turnbull, dan M. Crumlish, "Isolation and molecular characterization of streptococcal species recovered from clinical infections in farmed Nile tilapia (*Oreochromis niloticus*) in the Philippines," *J. Fish Dis.*, vol. 43, no. 11, hlm. 1431–1442, Nov 2020, doi: 10.1111/jfd.13247.
- [10] A. Ammar, S. Abdelgelel, B. Mohamed, dan A. Gharib, "Motile Aeromonads as a Nile Tilapia Bacterial Infection: A Review on Prevalence, Molecular Characterization, Effect on Immune Response and Alternatives Control Measures," *Zagazig Vet. J.*, vol. 51, no. 2, hlm. 112–128, Jun 2023, doi: 10.21608/zvjz.2023.181478.1199.
- [11] Doan T. N. *dkk.*, "Study on isolation and some pathological characteristics of Flavobacterium columnare causing infection in tilapia (*Oreochromis spp.*) cultured in Northern Vietnam," *Minist. Sci. Technol. Vietnam*, vol. 65, no. 2, hlm. 41–47, Feb 2023, doi: 10.31276/VJST.65(2).41-47.
- [12] S. A. El Gamal, R. S. Adawy, V. H. Zaki, dan E. Zahran, "Host–pathogen interaction unveiled by immune, oxidative stress, and cytokine expression analysis to experimental Saprolegnia parasitica infection in Nile tilapia," *Sci. Rep.*, vol. 13, no. 1, hlm. 9888, Jun 2023, doi: 10.1038/s41598-023-36892-w.
- [13] V. Kumar *dkk.*, "Outbreak of Ichthyophthirius multifiliis associated with Aeromonas hydrophila in Pangasianodon hypophthalmus: The role of turmeric oil in enhancing immunity and inducing resistance against co-infection," *Front. Immunol.*, vol. 13, hlm. 956478, Sep 2022, doi: 10.3389/fimmu.2022.956478.
- [14] A. Jutagate *dkk.*, "Adaptive artificial multiple intelligence fusion system (A-AMIFS) for enhanced disease detection in Nile Tilapia," *Aquac. Rep.*, vol. 39, hlm. 102418, Des 2024, doi: 10.1016/j.aqrep.2024.102418.
- [15] G. Singh, A. Dwivedi, A. Saluja, dan K. Rana, "Integrative AI Solutions: Designing a Web Application for Accurate Disease Diagnosis," *Int. J. Res. Publ. Rev.*, vol. 6, no. sp5, hlm. 94–100, Mei 2025, doi: 10.55248/gengpi.6.sp525.1913.
- [16] Ms. R. R. Owhal, Omkar Walke, Aditya Patne, dan Siddhesh Ranjane, "AgriSaathi: A Comprehensive Survey on Large Language Models and Multimodal AI for Agricultural Advisory Systems," *Int. J. Multidiscip. Res. IJFMR*, vol. 7, no. 6, 2024, doi: 10.2139/ssrn.5054029.
- [17] S. Devella, "Performance Analysis of MobileNetV2 and GhostNetV2 in Classifying Cervical Cancer Images in the SIPaKMeD Dataset," vol. 11, no. 1, 2026.
- [18] Jam Cyrex De Villa Delfino, Daniel James Bañez Manaloto, dan Edwin Romero Arboleda, "A comprehensive review of machine learning applications in tilapia aquaculture," *Int. J. Sci. Res. Arch.*, vol. 12, no. 1, hlm. 3008–3013, Jun 2024, doi: 10.30574/ijrsra.2024.12.1.1155.