

# Klasifikasi Jenis Ikan berdasarkan Citra Digital menggunakan Metode *Convolutional Neural Network*

## *Classification of Fish Species using Digital Images and Convolutional Neural Networks*

<sup>1</sup>Rosalva Denisia Yulia Yahya\*, <sup>2</sup>Wiwit Agus Triyanto, <sup>3</sup>Pratomo Setiaji

<sup>1,2,3</sup>Program Studi Sistem Informasi, Fakultas Teknik, Universitas Muria Kudus

<sup>1,2,3</sup>Jl. Lingkar Utara UMK, Gondangmanis, Bae, Kudus, Kodepos 59327, Jawa Tengah – Indonesia

\*e-mail: [salvadenisia@gmail.com](mailto:salvadenisia@gmail.com)

(received: 22 May 2026, revised: 4 June 2026, accepted: 5 June 2026)

### Abstrak

Penentuan jenis ikan merupakan langkah penting dalam industri perikanan, meskipun identifikasi secara manual masih sulit dan tidak efektif. Studi ini mengembangkan sistem klasifikasi otomatis menggunakan *Convolutional Neural Networks* (CNN) dengan arsitektur MobileNetV2 dan *Supervised learning*. Data dikumpulkan secara manual dari platform Roboflow dengan mencari semua jenis data sebelum digabungkan menjadi satu koleksi. Jenis ikan yang digunakan sebagai target klasifikasi adalah: Ikan Kakap Merah, Ikan Kakap Putih, dan Ikan Layang. Proses yang dilakukan meliputi augmentasi, normalisasi gambar, dan mengubah ukuran gambar menjadi 224x224. Setiap jenis ikan terdapat 500 gambar, dengan total 1500 gambar dari 3 jenis ikan. Data terbagi menjadi 70% data latih, 15% data validasi dan 15% data uji. *BatchNormalization*, *Dense* (128, ReLU), *Dropout* (0.6), dan *Dense* (3, *softmax*) adalah teknik klasifikasi yang digunakan untuk meningkatkan model MobileNetV2. Selama proses analisis, *Optimizer Adam* dengan *categorical cross-entropy loss* digunakan dalam tahap pelatihan. Hasil pengujian menunjukkan bahwa model tersebut mencapai akurasi 98,67% dengan *macro average F1-score* sebesar 0,99 pada data uji. Ini menunjukkan bahwa MobileNetV2 dengan *Supervised learning* sangat efektif untuk klasifikasi jenis ikan dari citra digital dan memberikan landasan kuat bagi pengembangan sistem identifikasi perikanan otomatis.

**Kata kunci:** CNN, klasifikasi, jenis ikan, MobileNetV2, roboflow

### Abstract

Accurate fish species identification is essential for fisheries management and the seafood industry; however, manual identification remains time-consuming, challenging, and prone to human error. This study develops an automated fish species classification system using a Convolutional Neural Network (CNN) based on the MobileNetV2 architecture with supervised learning. The dataset was manually collected from the Roboflow platform by gathering and integrating images from multiple sources into a single collection. Three fish species were selected as the target classes: Red Snapper, Barramundi (Asian Sea Bass), and Scad. The preprocessing pipeline included data augmentation, image normalization, and image resizing to 224 × 224 pixels. The final dataset consisted of 1,500 images, with 500 images per class, and was divided into training, validation, and testing sets using a 70:15:15 ratio. To enhance the classification performance of MobileNetV2, the proposed model incorporated a classification head consisting of Batch Normalization, a Dense layer (128 units, ReLU activation), Dropout (0.6), and a Dense output layer (3 units, Softmax activation). During training, the model was optimized using the Adam optimizer with the categorical cross-entropy loss function. Experimental results demonstrate that the proposed model achieved a test accuracy of 98.67% and a macro-averaged F1-score of 0.99. These findings indicate that MobileNetV2 with supervised learning is highly effective for fish species classification from digital images and provides a strong foundation for the development of automated fish identification systems in fisheries applications.

**Keywords:** CNN, classification, fish species, MobileNetV2, roboflow

## 1 Pendahuluan

Indonesia merupakan negara dengan kepulauan terbesar di dunia yang memiliki kekayaan sumber daya hayati laut yang sangat bernilai. Ribuan spesies ikan yang ditemukan di daerah laut dan tawar menjadi dasar ketahanan pangan nasional [1]. Namun, proses identifikasi yang akurat dalam spesies ikan masih menjadi tantangan besar karena saat ini masih dilakukan secara manual berdasarkan inspeksi visual, yang merupakan metode yang sangat bergantung pada kondisi fisik petugas, ketelitian, dan pengalaman [2].

Kemungkinan kesalahan manusia yang tinggi adalah masalah utama yang disebabkan oleh proses identifikasi yang dilakukan secara manual, terutama pada situasi di mana petugas harus memilah ribuan ikan dalam waktu yang singkat [3]. Jenis ikan yang memiliki kemiripan morfologi tinggi, seperti Kakap Merah dan Kakap Putih, memiliki kesamaan pada bentuk tubuh oval, struktur sirip, dan proporsi tubuh secara keseluruhan sehingga kerap menyebabkan kesalahan klasifikasi oleh pengepul dan pelaku pasar, terutama pada kondisi pencahayaan yang kurang optimal atau saat ikan sudah tidak dalam kondisi segar [4]. Selain itu, Ikan Layang yang memiliki kemiripan fisik dengan beberapa spesies ikan pelagis kecil lainnya juga sering menimbulkan kebingungan dalam proses identifikasi di lapangan, khususnya bagi nelayan dan pembudidaya yang belum berpengalaman [5].

Dalam konteks pengelolaan perikanan yang sudah modern, kebutuhan sistem klasifikasi otomatis semakin meningkat. Karena pengelolaan stok ikan yang berkelanjutan membutuhkan data tangkapan yang akurat, termasuk komposisi spesies yang ditemukan dalam setiap aktivitas penangkapan, klasifikasi spesies otomatis sangat penting bagi para petugas perikanan [6]. Untuk memungkinkan laporan hasil tangkapan yang akurat dan objektif tanpa bergantung sepenuhnya pada pengamatan manual, skema *electronic monitoring* pada kapal penangkap ikan komersial dibutuhkan agar laporan hasil tangkapan dapat diverifikasi secara objektif dan juga konsisten [7].

Solusi potensial yang ditawarkan adalah teknologi *Convolutional Neural Network* (CNN). CNN memiliki kemampuan untuk mempelajari dan mengekstraksi fitur visual dari gambar digital secara otomatis, yang membuatnya menjadi metode yang jauh lebih akurat dan efektif daripada metode pembelajaran mesin konvensional yang membutuhkan ekstraksi fitur secara manual [8]. Dengan penerapan arsitektur MobileNetV2 telah terbukti memiliki efisiensi komputasi yang lebih baik dan kinerja klasifikasi yang sangat baik [9].

Tujuan penelitian ini adalah untuk membuat sistem klasifikasi jenis ikan yang menggunakan CNN MobileNetV2 dan mengumpulkan dataset secara mandiri dari platform Roboflow. Teknik pengumpulan dataset yang diperbarui ini melibatkan pencarian ikan setiap jenis di Roboflow secara individual sebelum digabungkan ke dalam satu dataset terpadu [10]. Kemampuan CNN MobileNetV2 juga ditingkatkan melalui penerapan fine-tuning pada 30 *layer* terakhir agar dapat meningkatkan kemampuan pengenalan fitur visual ikan [11].

## 2 Tinjauan Literatur

Klasifikasi jenis ikan menggunakan teknologi komputer telah menjadi fokus penelitian yang berkembang pesat dalam beberapa tahun terakhir. Mol [2] melakukan studi klasifikasi ikan menggunakan *deep learning* dengan ekstraksi fitur berbasis penampilan, menunjukkan potensi besar metode berbasis CNN dalam membedakan spesies ikan secara akurat. Penelitian ini menjadi salah satu referensi utama yang menunjukkan kemampuan CNN dalam menangkap fitur morfologi ikan.

Sudhakara dkk. [3] mengkaji berbagai teknik klasifikasi ikan menggunakan CNN pada citra bawah air yang memiliki tantangan pencahayaan dan visibilitas rendah. Hasil penelitian mereka menunjukkan bahwa CNN tetap mampu menghasilkan klasifikasi yang baik meskipun dalam kondisi lingkungan yang sulit. Studi ini relevan karena menunjukkan *robustness* CNN terhadap variasi kondisi gambar. Menurut penelitian yang dilakukan oleh Zahra dan Firmansyah [12], CNN memiliki kemampuan untuk mengidentifikasi karakteristik visual ikan dengan klasifikasi yang tepat.

Pada domain klasifikasi ikan lokal Indonesia, penelitian oleh tim dari Universitas Sam Ratulangi [4] berhasil mengklasifikasikan ikan cakalang dan ikan tongkol menggunakan CNN dengan tingkat akurasi yang tinggi. Penelitian ini membuktikan bahwa CNN dapat diterapkan untuk spesies ikan yang memiliki kemiripan morfologi tinggi, seperti yang juga dijumpai dalam penelitian ini antara Kakap Merah dan Kakap Putih.

Perkembangan penelitian klasifikasi spesies ikan berbasis *deep learning* dalam beberapa tahun terakhir menunjukkan kemajuan yang sangat pesat, baik dari sisi arsitektur model maupun cakupan dataset yang digunakan. Mohammadisabet dkk. [13] membandingkan delapan arsitektur CNN, termasuk DenseNet121, MobileNetV2, dan Xception, untuk mengatasi tantangan variabilitas lingkungan, ketidakseimbangan kelas, dan efisiensi komputasi dalam klasifikasi ikan bawah air, dengan DenseNet121 mencapai akurasi tertinggi sebesar 90,2%, sementara MobileNetV2 menunjukkan keseimbangan antara akurasi dan efisiensi yang optimal untuk skenario *real-time*. Hasil ini menegaskan bahwa pemilihan arsitektur harus mempertimbangkan tidak hanya akurasi tetapi juga kebutuhan komputasi di lapangan, terutama untuk penerapan di lingkungan dengan sumber daya terbatas seperti yang umum dijumpai di kawasan perikanan Indonesia.

Dey [14] mengusulkan optimasi model MobileNetV2 yang berhasil mencapai rata-rata *validation accuracy* sebesar 99,83% dengan menetapkan panduan spesifik dalam pembuatan dataset dan augmentasi citra spesies laut, serta membuktikan bahwa model tersebut dapat digunakan secara langsung pada aplikasi *mobile* untuk klasifikasi di lokasi perikanan. Pencapaian ini relevan secara komparatif, mengingat penelitian tersebut menggunakan sembilan kelas ikan laut dengan pendekatan *transfer learning* berbasis bobot ImageNet yang serupa, sehingga memberikan tolak ukur yang lebih komprehensif bagi pengembangan sistem klasifikasi ikan berbasis MobileNetV2.

Malik [15] mengusulkan jaringan deteksi ikan bernama FD\_Net berbasis YOLOv7 yang dimodifikasi dengan mengganti ekstraksi fitur Darknet53 menggunakan MobileNetv3 dan *depthwise separable convolution*, serta meningkatkan DenseNet-169 dengan modul perhatian BNAM untuk klasifikasi sembilan spesies ikan. Model yang diusulkan mencapai mAP sebesar 95,30%, melampaui YOLOv3, YOLOv4, YOLOv5, dan Faster-RCNN, sekaligus memiliki jumlah parameter lebih sedikit sehingga lebih ringan dan cepat. Meskipun demikian, penelitian tersebut menggunakan dataset ikan umum yang tidak mencerminkan kondisi spesifik perairan Indonesia, sehingga masih terdapat kesenjangan pada spesies ikan konsumsi ekonomi tinggi seperti Kakap Merah, Kakap Putih, dan Ikan Layang yang membutuhkan pendekatan dataset yang lebih disesuaikan dengan karakteristik lokal.

Berdasarkan tinjauan terhadap penelitian-penelitian terkini tersebut, teridentifikasi bahwa sebagian besar studi baik yang menggunakan MobileNetV2 maupun DenseNet masih berfokus pada dataset internasional yang tidak merepresentasikan spesies ikan konsumsi utama Indonesia, menggunakan dataset publik yang sudah tersedia secara langsung tanpa proses kurasi mandiri per spesies, dan belum mengintegrasikan sistem prediksi berbasis web yang dapat langsung digunakan oleh pelaku perikanan. Penelitian ini mengisi celah tersebut dengan menggabungkan pengumpulan dataset mandiri per spesies dari platform Roboflow, strategi *fine-tuning* pada 30 lapisan terakhir MobileNetV2 yang terbukti efektif untuk dataset berukuran sedang, serta implementasi sistem prediksi berbasis web menggunakan Streamlit yang dilengkapi mekanisme validasi *confidence threshold* untuk tiga spesies ikan ekonomi penting Indonesia.

### 3 Metode Penelitian

Metode penelitian ini dirancang secara terstruktur untuk mendukung proses pengembangan sistem klasifikasi jenis ikan berbasis citra digital menggunakan pendekatan *Deep Learning*. Setiap tahapan penelitian disusun secara sistematis mulai dari pengumpulan dataset, *preprocessing* citra, perancangan arsitektur model, proses pelatihan, hingga evaluasi performa model agar penelitian dapat dilakukan secara terarah dan menghasilkan model yang optimal. Fokus utama dari penelitian ini adalah penerapan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2 untuk mengenali karakteristik visual dari masing-masing jenis ikan secara otomatis dan objektif.

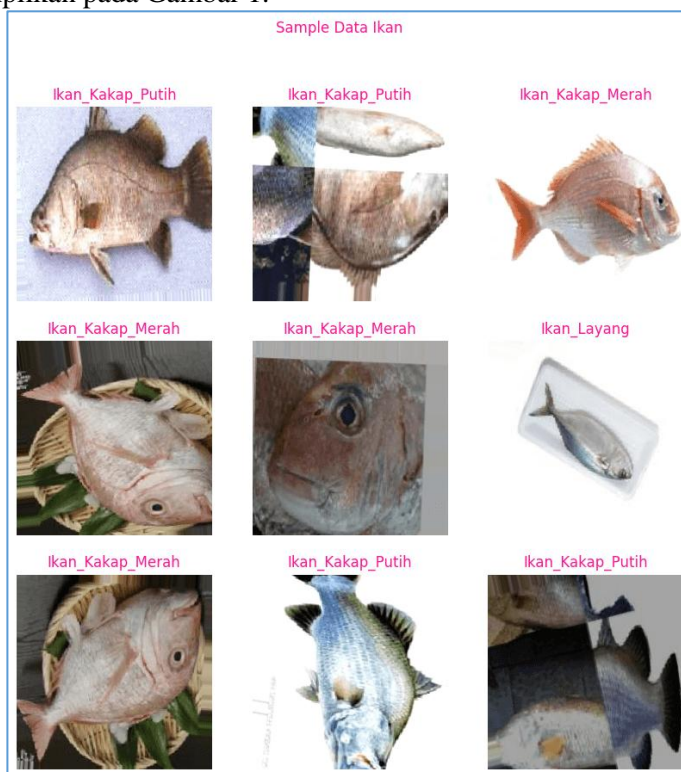
#### 3.1 Jenis dan Pendekatan Penelitian

Penelitian ini termasuk dalam penelitian terapan (*applied research*), yang merupakan penelitian eksperimental kuantitatif dengan tujuan agar dapat menemukan sebuah solusi yang bisa diterapkan secara langsung untuk masalah identifikasi ikan secara manual. Dengan menggunakan data citra ikan, proses pelatihan dan pengujian model CNN menunjukkan sifat eksperimental. Ini karena analisis kinerja model bergantung pada data numerik dan metrik evaluasi tertentu. Dengan label kelas yang jelas pada data gambar, pendekatan *Supervised learning* digunakan.

### 3.2 Dataset Penelitian

Dataset yang digunakan dalam penelitian ini dikumpulkan secara mandiri dari platform Roboflow (<https://roboflow.com>). Platform ini dipilih karena menyediakan citra dengan variasi kondisi pencahayaan, sudut pandang, dan latar belakang yang beragam sehingga lebih merepresentasikan kondisi nyata di lapangan. Dibandingkan dengan penggunaan dataset publik yang bersifat umum, Roboflow memungkinkan peneliti untuk melakukan pencarian spesies ikan secara spesifik, memberikan label yang sesuai pada setiap citra, serta menyesuaikan komposisi dataset dengan kondisi lokal Indonesia khususnya spesies ikan konsumsi yang umum diperdagangkan di pasar domestik.

Proses pengumpulan dilakukan dengan mencari setiap jenis ikan secara terpisah menggunakan kata kunci spesifik, kemudian menggabungkan hasil pencarian menjadi satu dataset terpadu. Tiga jenis ikan yang dipilih adalah: (1) Ikan Kakap Merah (*Red Sea Bream*), ikan konsumsi bernilai ekonomi tinggi dengan ciri khas warna merah cerah dan bentuk tubuh oval; (2) Ikan Kakap Putih (*Sea Bass*), memiliki tubuh lebih pipih dengan warna keperakan dan merupakan ikan budidaya utama di Indonesia; dan (3) Ikan Layang (*Horse Mackerel*), ikan pelagis kecil dengan tubuh ramping dan warna kebiruan yang sering menjadi komoditas tangkapan nelayan. Total dataset berjumlah 1.500 citra berlabel dengan distribusi seimbang yaitu 500 citra per kelas. Contoh sample citra dari masing-masing kelas ikan ditampilkan pada Gambar 1.



Gambar 1 Sample data ikan

### 3.3 Pembagian Dataset

Pada penelitian ini, dataset dibagi menjadi tiga subset dengan proporsi 70:15:15 sebagaimana ditampilkan pada Tabel 1, yaitu 70% data latih (1.050 citra) untuk melatih model mengenali pola visual, 15% data validasi (225 citra) untuk mengukur kinerja selama pelatihan dan mencegah overfitting, serta 15% data uji (225 citra) untuk mengukur kemampuan akhir model dalam mengklasifikasikan citra yang belum pernah dilihat sebelumnya.


Tabel 1 Pembagian dataset

Kelas Ikan	Train	Validation	Uji	Total
Kakap Merah	350	75	75	500
Kakap Putih	350	75	75	500
Layang	350	75	75	500

Total	1.050	225	225	1.500
-------	-------	-----	-----	-------

### 3.4 Preprocessing Data dan Augmentasi

Proses preprocessing bertujuan untuk memastikan bahwa semua gambar memiliki format dan sifat yang sama dengan persyaratan arsitektur MobileNetV2. Proses yang pertama adalah *resizing* gambar menjadi 224x224 *pixel* sebagai standar input gambar dari MobileNetV2. Proses kedua adalah normalisasi gambar dengan proses menggunakan fungsi preprocess input MobileNetV2 yaitu menormalkan nilai piksel dengan menggunakan standard input ImageNet [16]. Proses ketiga adalah data *augmentation* pada data *train*, meliputi: *rotasi* (*max degree*=15), *zoom* (*zoom*=15), *horizontal flip*, *translate height* dan *width* sebesar 10%, dan *brightness range* (*brightness\_range*=[0.8,1.2]) untuk mengurangi *overfitting* sekaligus meningkatkan variasi data dan kemampuan generalisasi model agar dapat mengenali objek dalam berbagai kondisi saat mengklasifikasikan gambar ikan [17]. Contoh hasil proses augmentasi pada citra ikan dapat dilihat pada Gambar 2.



Gambar 2 Contoh hasil augmentasi data citra ikan

### 3.5 Perangkat dan Tools Penelitian

Penelitian ini memanfaatkan beberapa perangkat lunak dan perangkat keras untuk mendukung proses pembuatan, pelatihan, serta pengujian model CNN dengan arsitektur MobileNetV2. Bahasa pemrograman yang digunakan adalah *Python* karena mudah digunakan dan memiliki banyak *library* yang mendukung pengolahan citra serta pengembangan *deep learning*. *Framework* yang digunakan dalam penelitian ini yaitu *TensorFlow* dan *Keras*, yang membantu proses pembuatan dan pelatihan model agar lebih praktis dan efisien. Pelatihan model dilakukan menggunakan *Google Colab* karena platform ini menyediakan lingkungan *Jupyter Notebook* berbasis *cloud* dan mendukung penggunaan *GPU* untuk mempercepat proses *training*. Selain menggunakan *Google Colab*, model juga dapat dijalankan pada perangkat lokal dengan spesifikasi yang cukup memadai, dengan *Ryzen 5*, *RAM 16 GB*, serta *GPU* agar proses pelatihan dapat berjalan lebih optimal.

### 3.6 Teknik Analisis Data dan Konfigurasi Arsitektur

Analisis data pada penelitian ini menggunakan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2 melalui pendekatan *supervised learning* menggunakan bobot pralatih (*pre-trained weights*) dari dataset *ImageNet* sebagai ekstraktor fitur citra ikan. Sebagian besar lapisan pada model dibekukan (*trainable = False*) untuk mempertahankan fitur dasar yang telah dipelajari sebelumnya, sedangkan beberapa lapisan akhir dilakukan *fine-tuning* agar model mampu mengenali karakteristik khusus dari masing-masing jenis ikan.

Lapisan klasifikasi tambahan (*classifier head*) yang digunakan terdiri atas *GlobalAveragePooling2D* dengan output sebesar 1280 dimensi, kemudian *BatchNormalization* untuk menjaga stabilitas pelatihan model, *Dense* (128, *ReLU*) sebagai lapisan *fully connected* untuk proses ekstraksi fitur lanjutan, konfigurasi lengkap setiap lapisan beserta jumlah parameternya dirangkum pada Tabel 2. Selanjutnya, *Dropout* untuk mengurangi *overfitting*. Pada bagian akhir digunakan


Dense (3, *softmax*) sebagai lapisan output untuk melakukan klasifikasi terhadap tiga jenis ikan. Model dikompilasi menggunakan *optimizer Adam* dengan fungsi kerugian *categorical crossentropy*.

**Tabel 2 Ringkasan arsitektur model**

	Layer (type)	Output Shape	Param #
0	Input Layer	(None, 224, 224, 3)	0
1	Conv2D	(None, 112, 112, 32)	864
2	BatchNormalization	(None, 112, 112, 32)	128
3	ReLu	(None, 112, 112, 32)	0
4	DepthwiseConv2D	(None, 112, 112, 32)	288
...	...	...	...
...	...	...	...
154	GlobalAveragePooling2D	(None, 1280)	0
155	BatchNormalization	(None, 1280)	5,120
156	Dense	(None, 128)	163,968
157	Dropout	(None, 128)	0
158	Dense	(None, 3)	387
Total params: 2, 353, 795			
Trainable params: 1, 637, 891			
Non-trainable params: 715, 904			

### 3.7 Tahapan Pelaksanaan Program

Tahapan program dimulai dari pengumpulan data, prapemrosesan dan augmentasi di VS Code, pelatihan hingga evaluasi akhir di Google Colab. Alur sistematis ini dipresentasikan dalam diagram alur pada Gambar 3.



**Gambar 3 Gambar diagram alur pelaksanaan program**

### 3.8 Proses Pelatihan Model

Pelatihan model dikonfigurasi dengan *optimizer Adam*, *loss function categorical cross-entropy*, dan metrik akurasi. Jumlah *epoch* maksimal ditetapkan 100 dengan batch size 16. Satu *callback* diterapkan, yaitu *ReduceLROnPlateau* yang mengurangi *learning rate* sebesar faktor 0.3 jika *val\_loss* tidak membaik selama 4 *epoch* berturut-turut dengan *learning rate* minimum  $1e-6$ . Pelatihan berjalan penuh hingga *epoch* ke-100 tanpa mekanisme penghentian dini. Pelatihan dilakukan di platform Google Colab memanfaatkan akselerasi GPU.

### 3.9 Evaluasi Model

Performansi dari model dinilai berdasarkan data test (test set) yang dinilai berdasarkan beberapa indikator, yakni akurasi total, *precision*, *recall*, nilai F1 untuk masing-masing kelas, serta *confusion matrix*. Adanya indikator-indikator tersebut menggambarkan performansi dari

model dalam mengidentifikasi 3 kelas dengan baik dan akurat.

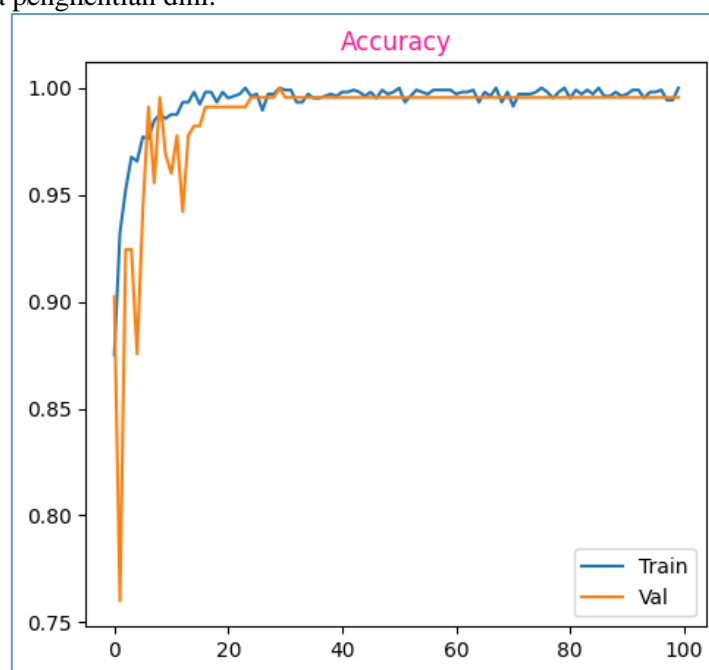
### 3.10 Arsitektur Model CNN MobileNetV2

Metode *Supervised learning* digunakan untuk model MobileNetV2. MobileNetV2 dipilih karena memiliki arsitektur CNN yang sangat efektif yang memanfaatkan *depthwise separable convolution* dan *inverted residual blocks* dengan *linear bottleneck* untuk mengurangi beban komputasi tanpa kehilangan akurasi yang signifikan [9]. Bagian dasar model MobileNetV2 dilengkapi dengan bobot *ImageNet* yang diatur dengan benar (*include\_top = False*, *input\_shape = 224 x 224 x3*). Sebagian besar lapisan dibekukan kecuali tiga puluh lapisan terakhir yang disesuaikan secara khusus untuk memungkinkan model untuk mempelajari fitur khusus ikan. Untuk tiga kelas ikan, *custom classifier head: GlobalAveragePooling2D, Batch Normalization, Dense (128, relu), Dropout (0.6), dan Dense (3, softmax)* ditambahkan ke atas base model.

## 4 Hasil dan Pembahasan

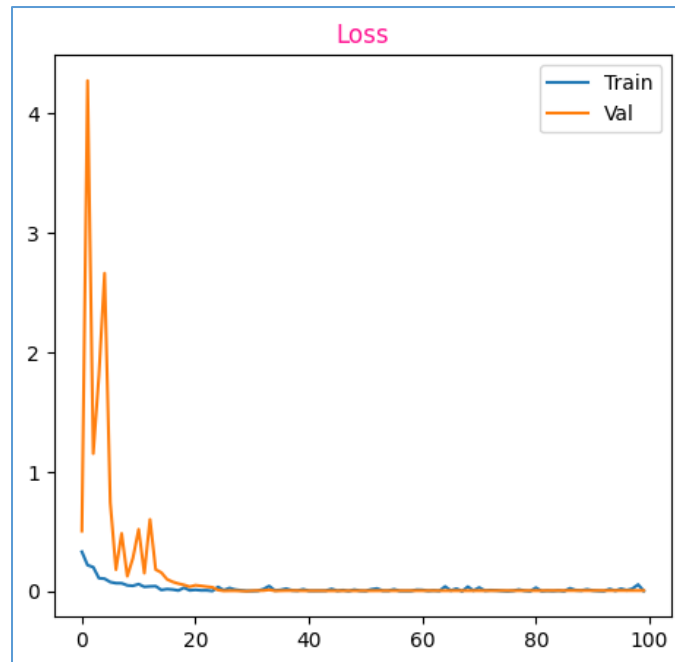
### 4.1 Hasil Pelatihan Model

Pelatihan model CNN MobileNetV2 dengan dataset yang diperoleh dari Roboflow yang mencakup gambar tiga spesies ikan telah berhasil. Terdapat penurunan dalam nilai *loss* pelatihan dan validasi secara stabil pada tiap periode. Hal ini karena fungsi *ReduceLROnPlateau* sukses mempertahankan pelatihan tetap stabil dengan menyesuaikan *learning rate* secara adaptif ketika nilai *val\_loss* tidak membaik selama 4 *epoch* berturut-turut, sehingga pelatihan dapat berjalan penuh hingga *epoch* ke-100 tanpa penghentian dini.



Gambar 4 Grafik akurasi

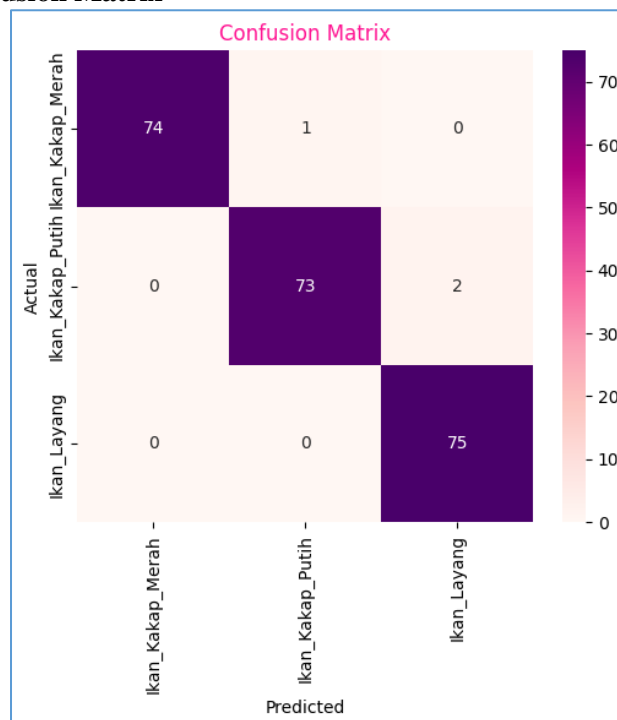
Grafik akurasi pada Gambar 4 menunjukkan tren peningkatan kinerja model selama pelatihan yang dikonfigurasi hingga 100 *epoch*, dan berjalan penuh hingga *epoch* ke-100 tanpa penghentian dini. Kurva *train accuracy* dimulai pada 87,52% dan *validation accuracy* pada 90,22%, di mana *validation accuracy* sudah melampaui *train accuracy* sejak *epoch* pertama karena pengaruh bobot pralatih. Meskipun terjadi fluktuasi pada *epoch* awal dengan *validation accuracy* turun hingga titik terendah ~75% sekitar *epoch* ke-2 hingga ke-3, model berhasil pulih secara bertahap dan mencapai *validation accuracy* stabil di kisaran 99–100% mulai *epoch* ke-7, dengan *train accuracy* akhir 100,00% pada *epoch* ke-100.



Gambar 5 Grafik loss

Grafik *loss* pada Gambar 5 menunjukkan penurunan nilai kesalahan model selama proses pelatihan berlangsung hingga *epoch* ke-100. Pada awal pelatihan, *train loss* dimulai pada ~0,33 dan *validation loss* langsung melonjak tajam pada titik tertinggi ~4,27 di *epoch* ke-2, diikuti lonjakan kedua yang lebih kecil sekitar ~2,70 pada *epoch* ke-10 hingga ke-11. Setelah *ReduceLRonPlateau* menyesuaikan *learning rate* secara adaptif, kedua kurva menunjukkan penurunan yang konsisten dan konvergen mendekati nol mulai sekitar *epoch* ke-20. Pada *epoch* terakhir, *train loss* mencapai ~0,004 dan *validation loss* ~0,003.

#### 4.2 Analisis Confusion Matrix



Gambar 6 Confusion matrix

*Confusion matrix* pada Gambar 6 menunjukkan hasil klasifikasi model terhadap 225 citra data uji yang terbagi dalam tiga kelas. Dari 75 citra Ikan Kakap Merah, sebanyak 74 diklasifikasikan dengan benar dan 1 salah diprediksi sebagai Ikan Kakap Putih. Dari 75 citra Ikan Kakap Putih, sebanyak 73 diklasifikasikan dengan benar dan 2 salah diprediksi sebagai Ikan Layang. Dari 75 citra Ikan Layang, seluruhnya diklasifikasikan dengan benar tanpa kesalahan sama sekali. Pola kesalahan yang terjadi dapat dianalisis dari dua sisi. Pertama, kesalahan pada Ikan Kakap Putih yang sebanyak 2 citra terprediksi sebagai Ikan Layang kemungkinan disebabkan oleh kemiripan karakteristik visual antara kedua kelas tersebut, khususnya bentuk tubuh memanjang dan kilap sisik yang serupa dalam kondisi pencahayaan tertentu. Kedua, kesalahan tunggal pada Ikan Kakap Merah yang terprediksi sebagai Ikan Kakap Putih kemungkinan disebabkan oleh citra dengan kondisi warna yang kurang jernih sehingga mengurangi kontras warna khas Kakap Merah. Sebaliknya, Ikan Layang tidak mengalami kesalahan klasifikasi sama sekali karena karakteristik visualnya paling mudah dibedakan di antara ketiga kelas, sehingga model dapat mengenalinya dengan keyakinan penuh. Secara keseluruhan, hasil ini konsisten dengan nilai *macro average F1-score* sebesar 0,99 yang menunjukkan kinerja model sangat baik dan seimbang di seluruh kelas.

#### 4.3 Analisis Per Kelas: *Precision*, *Recall*, *F1-Score*

Hasil evaluasi per kelas disajikan pada Tabel 3. Ikan Kakap Merah mencapai performa tertinggi dengan *precision* sempurna (1,00) dan *recall* 0,99 sehingga menghasilkan *F1-score* 0,99, yang berarti hampir seluruh citra Ikan Kakap Merah berhasil dikenali dengan benar dan tidak ada citra kelas lain yang salah diprediksi sebagai Ikan Kakap Merah. Ikan Kakap Putih memperoleh *precision* 0,99 dengan *recall* 0,97, artinya hampir setiap prediksi Ikan Kakap Putih selalu benar, namun terdapat beberapa citra Ikan Kakap Putih yang luput dikenali dan keliru diklasifikasikan sebagai kelas lain, sehingga *F1-score* sebesar 0,98. Ikan Layang memperoleh *recall* sempurna (1,00) dengan *precision* 0,97, yang berarti model sangat sensitif dalam mendeteksi seluruh citra Ikan Layang tanpa satu pun yang terlewat, namun sesekali mengklasifikasikan citra kelas lain ke dalam kategori ini, menghasilkan *F1-score* sebesar 0,99.

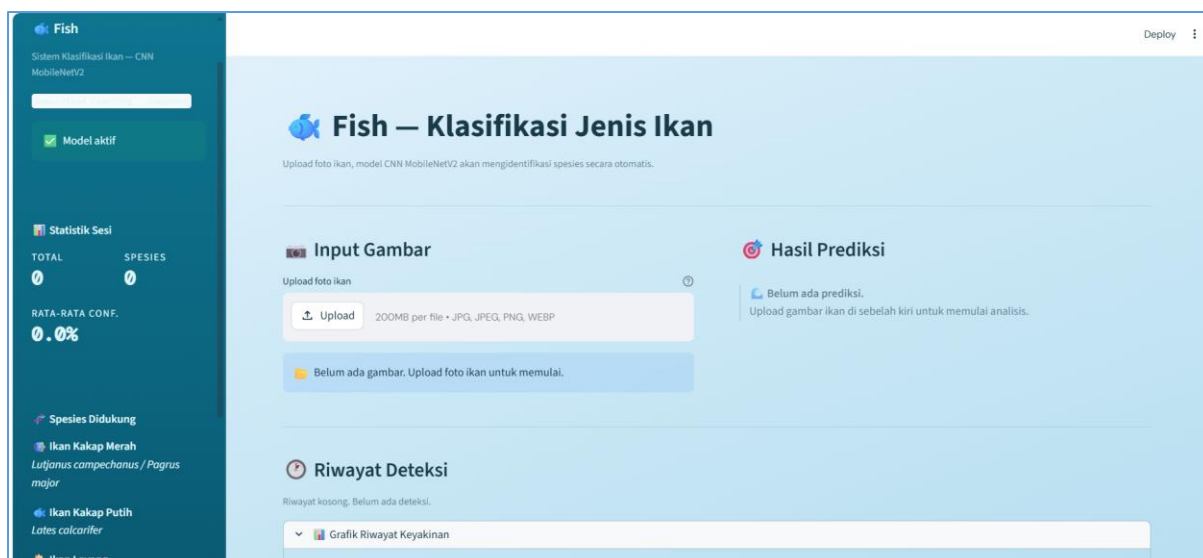
Nilai *macro average* untuk *precision*, *recall*, dan *F1-score* masing-masing sebesar 0,99, 0,99, dan 0,99 menunjukkan kinerja model yang sangat baik dan seimbang di ketiga kelas. Keseimbangan nilai *precision* dan *recall* yang hampir setara pada seluruh kelas mengindikasikan bahwa model tidak mengalami bias terhadap kelas tertentu, yang merupakan hasil langsung dari distribusi dataset yang seimbang antar kelas pada tahap augmentasi.

Tabel 3 Hasil evaluasi per kelas

Kelas Ikan	Precision	Recall	F1-Score	Support
Ikan Kakap Merah	1,00	0,99	0,99	75
Ikan Kakap Putih	0,99	0,97	0,98	75
Ikan Layang	0,97	1,00	0,99	75
Accuracy			0,99	225
Macro Avg	0,99	0,99	0,99	225
Weighted Avg	0,99	0,99	0,99	225

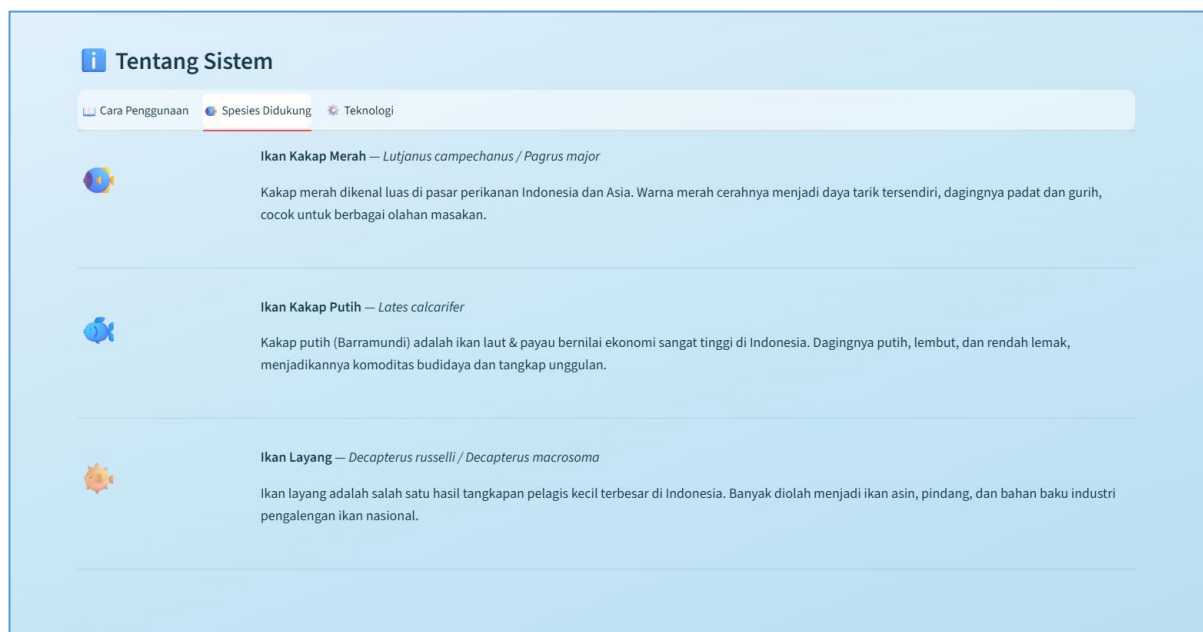
#### 4.4 Implementasi Sistem Prediksi Berbasis Web

Sistem prediksi berbasis web dibangun menggunakan *framework* Streamlit dengan nama "Fish - Klasifikasi Jenis Ikan" yang mengintegrasikan model CNN MobileNetV2. Sistem bekerja melalui dua tahap validasi berlapis: tahap pertama memverifikasi apakah citra yang diunggah merupakan objek ikan menggunakan MobileNetV2 berbasis ImageNet, dan tahap kedua mengklasifikasikan spesies ikan menggunakan model hasil pelatihan. Hasil prediksi hanya diterima apabila nilai *confidence* mencapai ambang batas minimum 70%, dan apabila berada di bawah ambang batas tersebut sistem secara otomatis menampilkan status "Tidak Dikenali" sebagai pengamanan tambahan untuk mengurangi risiko kesalahan klasifikasi.



**Gambar 7** Antarmuka sistem prediksi ikan berbasis web

Halaman utama aplikasi web 'Fish — Klasifikasi Jenis Ikan' pada Gambar 7 yang dibangun menggunakan *framework* Streamlit dan model CNN MobileNetV2. Antarmuka aplikasi menampilkan menu unggah gambar ikan, panel hasil prediksi, statistik sesi, daftar spesies yang didukung, serta riwayat deteksi. Pada kondisi awal, sistem belum melakukan prediksi karena belum ada gambar yang diunggah oleh pengguna.



**Gambar 8** Informasi spesies


Gambar 8 menampilkan halaman informasi spesies pada tab "Spesies Didukung" dalam aplikasi web *Fish — Klasifikasi Jenis Ikan*. Halaman ini menyajikan informasi detail mengenai tiga spesies ikan yang didukung oleh sistem, yaitu Ikan Kakap Merah (*Lutjanus campechanus / Pagrus major*), Ikan Kakap Putih (*Lates calcarifer*), dan Ikan Layang (*Decapterus russelli / Decapterus macrosoma*), masing-masing dilengkapi dengan ikon visual, nama ilmiah, serta deskripsi singkat mengenai karakteristik dan nilai ekonomi ikan tersebut, sehingga aplikasi tidak hanya berfungsi sebagai sistem klasifikasi tetapi juga sebagai media informasi edukatif bagi pengguna.

**Riwayat Deteksi**

#	Spesies	Nama Ilmiah	Confidence	Status	Ditolak di	File
1	Ikan Kakap Merah	Lutjanus campechanus / Pagrus major	100.0%	Valid	—	27_PNG.rf.2a152ee56aa972276220d69c9bfac81.jpg
2	Ikan Kakap Merah	Lutjanus campechanus / Pagrus major	100.0%	Valid	—	18_PNG.rf.b8bbba5ec1d26b7dc4d6f40abc5f1230.jpg
3	Ikan Kakap Merah	Lutjanus campechanus / Pagrus major	100.0%	Valid	—	10_PNG.rf.0a741de305a4b265b0edbf0cda03e9e2.jpg
4	Ikan Kakap Putih	Lates calcarifer	99.61%	Valid	—	th-2023-05-10T120057-101.jpg.rf.8522ce7ef74a11ee9a0ec3447bccf0d7.jp
5	Ikan Kakap Putih	Lates calcarifer	100.0%	Valid	—	th-2023-05-10T120057-101.jpg.rf.d310d6307919e75832cf820307465160.jp
6	Ikan Kakap Putih	Lates calcarifer	98.29%	Valid	—	th-2023-05-10T115448-968.jpg.rf.72e100f04abd1bb85dd22a7afd6bce97.j
7	Ikan Kakap Putih	Lates calcarifer	97.53%	Valid	—	th-2023-05-10T120108-403.jpg.rf.fed8e272e576cf9ed8eb83a0dab8262e.ji
8	Ikan Kakap Putih	Lates calcarifer	100.0%	Valid	—	th-2023-05-10T115448-968.jpg.rf.90c8edad4229d5fde165308d6cad8d42.j
9	Ikan Layang	Decapterus russelli / Decapterus macrosoma	100.0%	Valid	—	A270334XX_02389.jpg.rf.0fd254a1e8e4551c4e99d6f6d8d199a6.jpg
10	Ikan Layang	Decapterus russelli / Decapterus macrosoma	100.0%	Valid	—	A270334XX_01701.jpg.rf.c58bbe9911c2012af6e097785a499c05.jpg

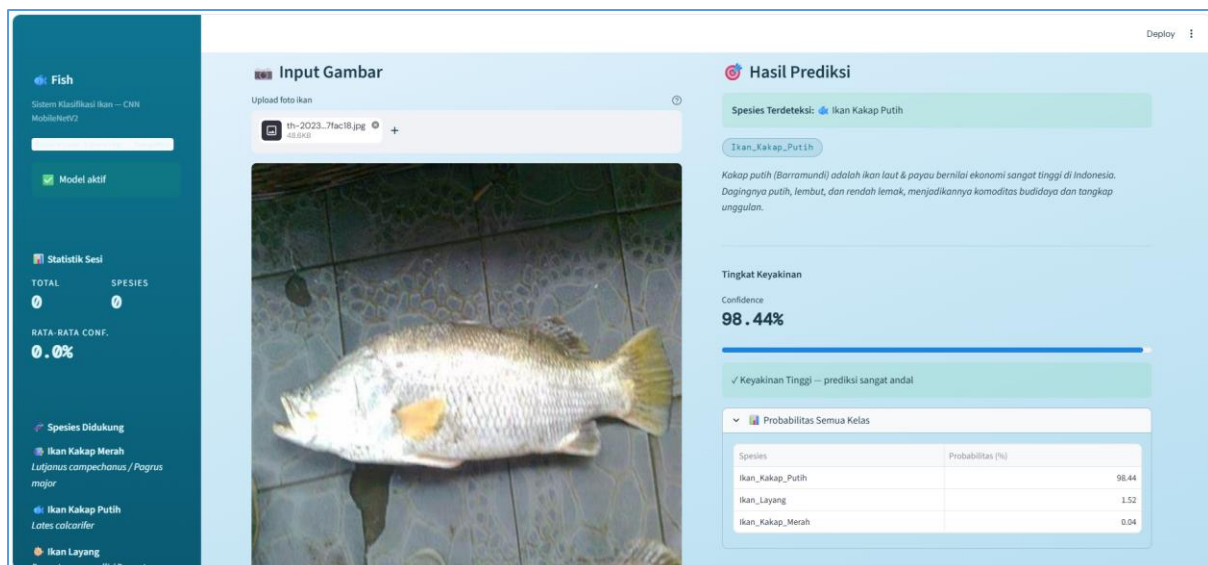
**Gambar 9 Riwayat Deteksi**

Pada Gambar 9 menampilkan halaman riwayat deteksi yang menyimpan seluruh hasil klasifikasi selama sesi aplikasi berlangsung, mencakup informasi nama spesies, nama ilmiah, nilai *confidence*, status validasi, dan nama file gambar. Setiap prediksi dengan nilai *confidence* di atas ambang batas minimum secara otomatis diberi status "Valid", dengan nilai *confidence* yang tercatat berada pada rentang 97% hingga 100%, menunjukkan bahwa model mampu mengidentifikasi spesies ikan dengan tingkat keyakinan yang sangat tinggi. Fitur ini memudahkan pengguna dalam memantau hasil pengujian, mengevaluasi performa model, serta mendokumentasikan proses klasifikasi yang telah dilakukan.



**Gambar 10 Grafik hasil prediksi**

Gambar 10 menampilkan grafik batang hasil prediksi sistem terhadap 10 citra uji (1 hingga 10) yang memperlihatkan nilai *confidence* masing-masing prediksi pada sumbu vertikal dengan garis putus-putus oranye sebagai batas ambang minimum (*threshold*) sebesar 70%. Seluruh prediksi ditampilkan dengan warna biru yang menandakan status "Valid", dengan nilai *confidence* yang hampir seluruhnya mencapai 99–100%, jauh melampaui batas *threshold* yang ditetapkan, sehingga menunjukkan bahwa model CNN MobileNetV2 mampu mengklasifikasikan spesies ikan dengan tingkat keyakinan yang sangat tinggi dan konsisten pada setiap pengujian yang dilakukan.



Gambar 11 Contoh hasil pengujian sistem

Gambar 11 menunjukkan salah satu contoh hasil pengujian pada aplikasi Fish — Klasifikasi Jenis Ikan menggunakan citra uji spesies Ikan Kakap Putih. Setelah gambar diunggah oleh pengguna, sistem secara otomatis melakukan proses inferensi menggunakan model CNN MobileNetV2 dan berhasil mengidentifikasi objek sebagai Ikan Kakap Putih dengan nilai *confidence* sebesar 98,44%. Pada halaman hasil prediksi, sistem menampilkan nama spesies yang terdeteksi, tingkat keyakinan model, indikator status prediksi, serta probabilitas seluruh kelas yang tersedia pada model klasifikasi. Tingginya nilai *confidence* menunjukkan bahwa model mampu mengenali karakteristik visual ikan dengan sangat baik, seperti bentuk tubuh, pola warna tubuh, dan struktur morfologi khas ikan.

Selain hasil prediksi utama, sistem juga menampilkan informasi singkat mengenai spesies ikan yang terdeteksi untuk memberikan nilai edukatif kepada pengguna. Statistik sesi pada panel sebelah kiri turut memperlihatkan jumlah total pengujian, jumlah spesies yang berhasil dikenali, dan rata-rata *confidence* dari seluruh proses klasifikasi yang telah dilakukan selama sesi aplikasi berlangsung.

## 5 Kesimpulan

Penelitian ini berhasil membangun sistem klasifikasi jenis ikan berbasis citra digital menggunakan arsitektur MobileNetV2 dengan pendekatan *supervised learning*. Model mencapai akurasi uji sebesar 98,67% pada tiga kelas, yaitu Ikan Kakap Merah, Ikan Kakap Putih, dan Ikan Layang. Hasil klasifikasi per kelas menunjukkan bahwa Ikan Kakap Merah memperoleh *precision* 1,00 dan *recall* 0,99 (*F1-score*: 0,99), Ikan Kakap Putih memperoleh *precision* 0,99 dan *recall* 0,97 (*F1-score*: 0,98), serta Ikan Layang memperoleh *precision* 0,97 dan *recall* 1,00 (*F1-score*: 0,99). Nilai *macro average F1-score* sebesar 0,99 dengan distribusi kelas yang seimbang mengindikasikan bahwa model tidak mengalami bias terhadap kelas tertentu dan mampu melakukan generalisasi dengan baik.

Meskipun terdapat lonjakan *validation loss* pada *epoch* awal yang mencapai ~4,27, model berhasil menstabilkan performa berkat mekanisme *ReduceLRonPlateau* yang menyesuaikan *learning rate* secara adaptif hingga pelatihan berjalan penuh 100 *epoch*. Kombinasi augmentasi data, strategi *fine-tuning* pada 30 lapisan terakhir MobileNetV2, serta mekanisme *ReduceLRonPlateau* terbukti efektif dalam meningkatkan performa model dan membantu mengurangi *overfitting*. Selain itu, model berhasil diimplementasikan ke dalam sistem prediksi berbasis web menggunakan *framework Streamlit* dengan mekanisme validasi dua tahap dan *confidence threshold* 70%, yang terbukti mampu mengklasifikasikan spesies ikan dengan tingkat keyakinan 97–100% pada pengujian nyata.

Untuk penelitian selanjutnya, beberapa rekomendasi dapat dipertimbangkan. Pertama, perluasan dataset dengan menambah kelas spesies ikan konsumsi penting lainnya seperti Ikan Tuna, Ikan Kerapu, dan Ikan Bandeng disertai sumber citra untuk memperkuat kemampuan generalisasi model. Kedua, eksplorasi arsitektur *deep learning* yang lebih ringan seperti MobileNetV3 atau

EfficientNet-Lite guna mengoptimalkan performa pada perangkat *edge* di lingkungan perikanan terpencil.

## Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Dr. Ir. Wiwit Agus Triyanto, S.Kom., M.Kom., IPM., ASEAN Eng. dan Dr. Pratomo Setiaji, S.Kom., M.Kom. selaku dosen pembimbing yang telah memberikan bimbingan dan arahan dalam pelaksanaan penelitian ini. Terima kasih juga kepada Program Studi Sistem Informasi Fakultas Teknik Universitas Muria Kudus atas dukungan akademis yang diberikan. Penulis juga menyampaikan terima kasih kepada Roboflow yang telah menyediakan dataset citra ikan secara terbuka sehingga penelitian ini dapat terlaksana dengan baik.

## Referensi

- [1] H. Latuconsina, K. Amri, Dan R. Triyanti, "Peran Penting Pengelolaan Perikanan Laut Berkelanjutan Bagi Kelestarian Habitat dan Kemanfaatan Sumber Daya," Hal. 1–22, 2023, DOI: 10.55981/Brin.908.C751.
- [2] J. M. J. Mol Dan S. Albin Jose, "Fish Species Classification using Deep Learning and Appearance- based Feature Extraction," Journal Of Electrical Systems, Vol. 20, No. 2, Hal. 2531–2546, 2024, DOI: 10.52783/Jes.2026.
- [3] M. Sudhakara, M. J. Meena, O. R. R. V. Mahalakshmi, Dan A. Balobaid, "A Study on Fish Classification Techniques using Convolutional Neural Networks on Highly Challenged Underwater Images," International Journal On Recent And Innovation Trends In Computing And Communication, Vol. 10, No. 4, Hal. 1–9, 2022, DOI: 10.17762/Ijritcc.V10i4.5524.
- [4] W. A. Tonapa, P. D. K. Manembu, dan F. D. Kambey, "Fish Classification of Skipjack and Mackerel Tuna using Convolutional Neural Network," Jurnal Teknik Informatika, Vol. 19, No. 01, Hal. 31–36, Jan. 2024, DOI: 10.35793/Jti.V19i01.52013.
- [5] M. Taufik, A. Sa, Dan B. Sugiarto, "Implementasi Convolutional Neural Network (CNN) untuk Klasifikasi Ikan Cupang berbasis Mobile," Digital Transformation Technology, Vol. 3, No. 2, Hal. 712–723, Des. 2023, DOI: 10.47709/Digitech.V3i2.3245.
- [6] S. Akter Lima, "Interpretable Fish Classification Through Mobilenetv2 and Grad-Cam Visualization," International Journal Of Research in Engineering, Science and Management, Vol. 7, No. 9, Hal. 93–99, Sep. 2024, DOI: 10.62527/Jitsi.6.2.471.
- [7] M. Saqib Dkk., "Fishing Event Detection and Species Classification using Computer Vision and Artificial Intelligence for Electronic Monitoring," Fish. Res., Vol. 280, No. August, Hal. 107141, 2024, DOI: 10.1016/J.Fishres.2024.107141.
- [8] A. Mohanty, G. Goldsztein, Dan R. Pellegrin, "Fish Species Image Classification using Convolutional Neural Networks," Journal Of Student Research, Vol. 11, No. 3, Hal. 1–12, 2022, DOI: 10.47611/Jsrhs.V11i3.3058.
- [9] A. R. M. Anthony Christ Hartono, "Penerapan Transfer Learning Mobilenetv2 pada Klasifikasi Citra Jenis Buah-Buahan," Journal of Information System and Application Development, Vol. 3, No. 2, Hal. 103–111, Sep. 2025, DOI: 10.26905/Jisad.V3i2.16187.
- [10] M. Francescangeli Dkk., "Image Dataset for Benchmarking Automated Fish Detection and Classification Algorithms," Scientific Data, Vol. 10, No. 1, pp. 1–13, Jan. 2023, DOI: 10.1038/s41597-022-01906-1.
- [11] T. B. Sasongko Dan A. Amrullah, "Effect Analysis of Dataset Augmentation and Fine Tune On Pre- Trained Convolutional Neural Network (CNN) Algorithm," Vol. 10, No. 4, Hal. 763–768, 2023, DOI: 10.25126/Jtiik.2023106583.
- [12] F. A. Zahra Dan N. Firmansyah, "Klasifikasi Citra Jenis Ikan Air Tawar dan Air Laut menggunakan Algoritma CNN (Convolutional Neural Network)," Jurnal Informatika Polinema, Vol. 11, No. 4, Hal. 495–502, 2023, DOI: 10.33795/Jip.V11i4.7600.
- [13] A. Mohammadisabet, R. Hasan, V. Dattana, Dan S. Mahmood, "CNN-based Optimization For Fish Species Classification : Tackling Environmental Variability , Class Imbalance , and Real-Time Constraints," Journal Information, Vol. 16, No. 2, Hal. 1–33, 2025, DOI: 10.3390/Info16020154.
- [14] K. Dey, K. Bajaj, Dan S. Thomas, "Fishook - An Optimized Approach to Marine Species

- Classification using Mobilenetv2*". Oceans 2023 - Limerick, Limerick, Irlandia, 2023, Hal. 1–7, DOI: 10.1109/Oceanslimerick52467.2023.10244558.
- [15] H. Malik, A. N. Id, S. Hassan, F. Ali, dan D. K. Yon, "*Multi-Classification Deep Neural Networks for Identification of Fish Species using Camera Captured Images*". Plos One, Vol. 18, No. 4, Hal. 1-32, April. 2023, DOI: 10.1371/Journal.Pone.0284992.
- [16] T. S. D. Koteswar Rao, K. Sahiti, J. Vamshi, K.Uday Kiran, "*Deep Learning-based Food Image Classification using Enhanced CNN Architecture and Data Augmentation Techniques*," International Journal Of Computer Engineering In Research Trends, Vol. 11, No. 1, Hal. 16–22, 2024, DOI: 10.22362/Ijcert/2024/V11/I1/V11i1s03.
- [17] M. A. Al-Fahrezi, "*The Effect of Data Augmentation on the Accuracy of CNN Model Training for Fish Type Classification*," Jitsi: Jurnal Ilmiah Teknologi Sistem Informasi, Vol. 6, No. 2, Hal. 177–185, Jun. 2025, DOI: 10.62527/Jitsi.6.2.471.