

Peningkatan Akurasi Klasifikasi Ikan kepe-kepe (Famili Chaetodontidae) dengan EfficientNetV2 dan Bayesian Hyperparameter Tuning

I Gusti Agung Putu Mahendra^{1,*}, Muhammad Ikhsan Wibowo², Zuliari Efendi²

¹Program Studi D4 Rekayasa Perangkat Lunak, Teknik Informatika, Politeknik Negeri Bengkalis, Riau, Indonesia

²Program Studi D4 Keamanan Sistem Informasi, Teknik Informatika, Politeknik Negeri Bengkalis, Riau, Indonesia

Email: ^{1*}agungmahendra@polbeng.ac.id, ²mikhsanw@polbeng.ac.id, ³zuliarefendi@polbeng.ac.id

Email Penulis Korespondensi: agungmahendra@polbeng.ac.id*

Submitted: 18/08/2025; Accepted: 01/11/2025; Published: 31/12/2025

Abstrak— Identifikasi cepat dan akurat spesies Chaetodontidae penting untuk monitoring keanekaragaman hayati laut, namun pendekatan manual tidak skala dan rentan kesalahan pada dataset besar. GAP riset yang kami tangani adalah: (i) ketiadaan kajian yang secara khusus mengombinasikan EfficientNetV2 dengan Bayesian hyperparameter tuning untuk klasifikasi Chaetodontidae, dan (ii) belum adanya evaluasi yang menekankan efisiensi penalaan adaptif beserta dampaknya terhadap performa. Kebaruan (novelty) studi ini ialah perancangan pipeline ringkas-efisien berbasis EfficientNetV2 dengan Bayesian Optimization (10 percobaan) pada learning rate, dropout, dan unfreeze backbone, dipadukan augmentasi kuat (MixUp, CutMix) serta regularisasi (label smoothing, L2). Dataset mencakup 1.427 citra/13 spesies dengan praproses center-crop 80% dan resize 224×224. Konfigurasi terbaik (unfreeze=True, dropout=0.2, LR 3.73×10^{-4}) mencapai val-accuracy 92,75% dan akurasi uji 97%, dengan precision-recall rata-rata >95%, menunjukkan generalisasi yang baik bahkan pada kelas bermorfologi mirip. Dibanding penalaan manual/grid, pendekatan ini lebih hemat eksperimen sekaligus meningkatkan akurasi. Temuan tersebut menegaskan bahwa integrasi EfficientNetV2 + Bayesian tuning efektif dan siap diadopsi untuk sistem identifikasi-monitoring ikan berbasis citra pada konteks konservasi laut Indonesia.

Kata Kunci: Klasifikasi Citra; EfficientNetV2; Bayesian Hyperparameter Tuning; Ikan kepe-kepe (Famili Chaetodontidae); Augmentasi Data; Deep Learning

Abstract— Fast and accurate identification of Chaetodontidae species is crucial for marine biodiversity monitoring, but manual approaches do not scale and are error-prone on large datasets. The research gaps we address are: (i) the absence of studies specifically combining EfficientNetV2 with Bayesian hyperparameter tuning for Chaetodontidae classification, and (ii) the absence of evaluations emphasizing the efficiency of adaptive tuning and its impact on performance. The novelty of this study is the design of a compact-efficient pipeline based on EfficientNetV2 with Bayesian Optimization (10 trials) on learning rate, dropout, and unfreeze backbone, combined with strong augmentation (MixUp, CutMix) and regularization (label smoothing, L2). The dataset includes 1,427 images/13 species with 80% center-crop preprocessing and 224×224 resizing. The best configuration (unfreeze=True, dropout=0.2, LR 3.73×10^{-4}) achieved a val-accuracy of 92.75% and a test accuracy of 97%, with an average precision-recall >95%, indicating good generalization even across similar morphological classes. Compared to manual/grid tuning, this approach saves experimentation while improving accuracy. These findings confirm that the integration of EfficientNetV2 + Bayesian tuning is effective and ready to be adopted for image-based fish identification-monitoring systems in the context of Indonesian marine conservation.

Keywords: Image Classification; EfficientNetV2; Bayesian Hyperparameter Tuning; Butterfly Fish; Data Augmentation; Deep Learning

1. PENDAHULUAN

Indonesia merupakan negara dengan keanekaragaman hayati laut yang sangat tinggi, salah satunya tercermin dari banyaknya spesies ikan hias, seperti Ikan kepe-kepe (Famili Chaetodontidae) (kepe-kepe) [1]. Ikan kepe-kepe (Famili Chaetodontidae) memiliki peranan penting secara ekologis maupun ekonomi, baik sebagai indikator kesehatan terumbu karang maupun sebagai komoditas perdagangan ikan hias. Namun, berbagai tekanan lingkungan, eksploitasi berlebihan, serta degradasi habitat telah mengancam keberlangsungan populasinya [2].

Identifikasi manual oleh pakar taksonomi akurat tetapi tidak skala untuk pemantauan rutin berskala besar maupun situasi lapangan real-time. Di sisi lain, deep learning berbasis CNN terbukti efektif untuk klasifikasi biota laut, namun performanya sangat bergantung pada pemilihan hyperparameter (mis. learning rate, batch size, dropout) [3]. Pendekatan konvensional (grid/random) kerap boros komputasi dan tidak adaptif, sehingga hasil dapat kurang stabil. Bayesian Optimization menawarkan penalaan otomatis yang lebih hemat eksperimen dan cepat konvergen

Sejumlah penelitian terkait dalam lima tahun terakhir dapat dijadikan rujukan untuk melihat perkembangan dan celah (gap) penelitian yang ada. Terdapat penelitian mengembangkan sistem klasifikasi ikan air tawar berbasis CNN custom dan augmentasi citra, namun tidak mengeksplorasi arsitektur efisien seperti EfficientNetV2 atau optimasi hyperparameter otomatis [4]. Sementara itu, terdapat penelitian memanfaatkan transfer learning dengan ResNet untuk identifikasi ikan laut dan memperoleh akurasi tinggi, namun tuning hyperparameter masih dilakukan secara manual dan belum adaptif [5]. Selanjutnya penelitian menerapkan MobileNetV2 pada klasifikasi ikan hias Indonesia dengan hasil akurasi yang kompetitif, namun tanpa penggunaan pendekatan automated hyperparameter tuning seperti Bayesian Optimization [6]. Selanjutnya penelitian yang

melakukan perbandingan grid search dan random search pada tuning *hyperparameter CNN* untuk identifikasi ikan karang, menunjukkan bahwa grid search sedikit lebih unggul, namun prosesnya tetap boros komputasi dan belum memanfaatkan teknik adaptif [7] menunjukkan bahwa penggunaan *Bayesian Optimization* pada tuning model *deep learning* mampu mempercepat konvergensi dan meningkatkan akurasi pada domain non-perikanan, namun penerapannya pada kasus klasifikasi ikan masih sangat terbatas [8].


Dari tinjauan literatur di atas, terlihat adanya beberapa gap penelitian yang menjadi fokus utama penelitian ini. Pertama, masih minim studi yang memadukan EfficientNetV2 dengan *Bayesian Hyperparameter Tuning* untuk klasifikasi citra ikan. Kedua, penelitian yang secara komprehensif mengevaluasi dampak optimasi *hyperparameter* adaptif terhadap peningkatan performa dan efisiensi pelatihan model *deep learning* pada klasifikasi biota laut juga masih sangat terbatas. Ketiga, diperlukan pipeline modern yang mengintegrasikan augmentasi cerdas (seperti MixUp dan CutMix), regularisasi lanjutan (seperti label smoothing dan L2), serta optimasi *hyperparameter* berbasis probabilistik, agar dapat menghasilkan model yang kuat, efisien, dan siap di-deploy pada sistem monitoring nyata di lapangan.

Berdasarkan latar belakang dan gap penelitian tersebut, tujuan utama penelitian ini adalah mengembangkan pipeline klasifikasi spesies Ikan kepe-kepe (*Famili Chaetodontidae*) berbasis citra menggunakan EfficientNetV2 dan *Bayesian Hyperparameter Tuning*. Penelitian ini juga bertujuan untuk menganalisis dampak integrasi berbagai teknik augmentasi dan regularisasi pada performa model. Harapannya, hasil penelitian dapat memberikan kontribusi nyata dalam pengembangan sistem identifikasi ikan otomatis yang lebih akurat dan efisien, sekaligus menjadi rujukan untuk pengembangan lebih lanjut pada klasifikasi biota laut lain yang mendukung konservasi keanekaragaman hayati di Indonesia.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Beberapa tahapan dalam penelitian ini menggambarkan langkah-langkah yang diambil selama proses penelitian berlangsung. Seluruh proses dilakukan secara sistematis sesuai rencana yang telah ditetapkan untuk memastikan penelitian berjalan secara terstruktur dan mampu mencapai tujuan yang diinginkan[9]. Gambaran keseluruhan alur penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Prosedur Penelitian

2.2 Studi Pustaka










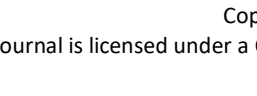
Tahap pertama penelitian ini adalah melakukan studi pustaka menyeluruh untuk membangun landasan teoretis dan teknis. Kami mengulas karakteristik morfologi dan ekologi berbagai spesies ikan *butterfly*, serta tantangan identifikasi manual di lapangan. Selanjutnya, ditelaah teknik pengolahan citra—termasuk metode crop, resize, dan normalisasi—yang kerap dipakai dalam praproses dataset. Bagian berikutnya mendalami perkembangan *Convolutional Neural Network (CNN)* untuk klasifikasi citra, dengan fokus pada arsitektur modern seperti EfficientNetV2 yang menawarkan scaling adaptif dan efisiensi komputasi. Terakhir, kami mempelajari metode

otomatisasi tuning *hyperparameter*, terutama *Bayesian Optimization* dan *Hyperband*, serta regularisasi seperti label smoothing dan weight decay, untuk meminimalkan overfitting dan mempercepat konvergensi model *deep learning*.

2.3 Pengumpulan Dataset

Dataset berisi 1.427 citra dari 13 spesies *Famili Chaetodontidae*. Tantangan utama berasal dari kemiripan morfologi/warna antarkelas (mis. Kepe-kepe Matahari vs Coklat; Auriga vs Bulan Menangis), refleksi kaca/gelembung pada akuarium, dan pose/arah ikan yang beragam. Distribusi data uji per kelas ditunjukkan pada Tabel 1. terlihat ketimpangan (mis. 98 untuk Angsa vs 14 untuk Monyong Kuning), sehingga pada evaluasi kami menekankan metrik macro (bukan hanya akurasi).. Dataset dapat dilihat pada Tabel 1.

Tabel 1. Dataset ikan *butterfly*

No	Gambar Citra	Nama Spesies
1		Kepe-Kepe Angsa
2		Kepe-Kepe Auriga
3		Kepe-Kepe Bulan Biasa
4		Kepe-Kepe Bulan Menangis
5		Kepe-Kepe Coklat
6		Kepe-Kepe Lurik Tembaga
7		Kepe-Kepe Matahari
8		Kepe-Kepe Monyong Kuning
9		Kepe-Kepe Nanas
10		Kepe-Kepe Punggung Hitam



2.4 Hasil Pre-processing & Augmentasi (MixUp dan Cut Mix)

Pada tahap preprocessing, setiap citra pertama-tama dipangkas (“center-crop”) secara presisi dengan mengambil 80 % area tengah gambar. Langkah ini memastikan bahwa sebagian besar piksel yang berisi objek ikan—dan sekaligus memotong tepi yang sering berisi noise atau bagian wadah—dipertahankan, sehingga model dapat lebih fokus menangkap pola morfologi ikan. Setelah proses pemotongan selesai, hasilnya diubah ukurannya (resize) menjadi resolusi 224×224 piksel. Ukuran ini dipilih untuk memenuhi persyaratan input EfficientNetV2 sekaligus mempertahankan rasio aspek yang wajar, sehingga semua detail bentuk dan warna ikan tetap terjaga dan konsisten di seluruh sampel sebelum dilanjutkan ke pipeline augmentasi dan pelatihan. Dapat dilihat pada Gambar 2.




Gambar 2. Hasil pre-processing

Selanjutnya, seluruh batch training secara bergantian dikenai teknik MixUp $def\ mixup(imgs, lbls, alpha=0.2)$, yaitu kombinasi linier dua citra dan labelnya sehingga model terlatih pada campuran pola visual Mixup bekerja dengan mengombinasikan warna dari dua citra dan labelnya. Pada beberapa eksperimen yang telah diterapkan pada kumpulan data ImageNet-2012, CIFAR10, CIFAR-100, Google, dan UCI menunjukkan bahwa Mixup dapat meningkatkan kemampuan generalisasi arsitektur JST yang canggih. Penelitian tersebut juga menemukan bahwa mixup dapat mengurangi pengenalan label yang tidak lengkap dan menstabilkan pelatihan adversarial generative networks [10]. Ilustrasi hasil augmentasi mixup dapat dilihat pada Gambar 3.



Gambar 3. Augmentasi data dengan MixUp

CutMix merupakan salah satu jenis augmentasi data citra yang pada prosesnya melakukan cut dan paste pada bagian acak piksel pada sebuah data latih citra. CutMix diusulkan untuk menggantikan salah satu metode regional dropout yang mengganti suatu bagian dari citra dengan piksel hitam. Hal ini bisa menghilangkan informasi penting yang terdapat dalam citra tersebut. Oleh karena itu daripada menghilangkan salah satu bagian dari citra lebih baik mengganti bagian yang dihilangkan tersebut dengan citra yang lain secara proporsional agar suatu model bisa lebih fokus pada bagian yang tidak terlalu diskriminatif pada objek $def\ cutmix(imgs, lbls, alpha=1.0)$ [11]. Ilustrasi hasil augmentasi CutMix dapat dilihat pada Gambar 4.



Gambar 4. Augmentasi data dengan CutMix


MixUp dan CutMix digunakan untuk mengatasi kemiripan antarkelas dan ketimpangan data, sedangkan center-crop 80% diterapkan untuk mengurangi noise latar, sehingga keseluruhan pipeline menjadi lebih robust dan efisien. Dengan mengimplementasikan MixUp dan CutMix pada 100 % batch, pipeline augmentasi ini tidak hanya memperbanyak ragam tekstur dan komposisi yang dilihat model, tetapi juga membantu meratakan kontribusi setiap kelas—terutama untuk menangani class imbalance—serta memperkuat daya generalisasi sehingga overfitting dapat diminimalkan.

2.5 EfficientNetV2

Pemilihan metode dan parameter pada penelitian ini didasarkan pada pertimbangan teoretis dan bukti empiris. EfficientNetV2 dipilih karena menawarkan rasio akurasi–biaya yang baik pada resolusi input 224×224 serta mampu menangkap detail tekstur halus pada citra rusa. EfficientNetV2 adalah salah satu arsitektur *Convolutional Neural Network (CNN)* yang dirancang untuk menangani tugas pengenalan dan klasifikasi citra dengan tingkat efisiensi dan akurasi yang tinggi. Arsitektur ini merupakan penyempurnaan dari EfficientNet yang dikembangkan oleh Google Research. Dibandingkan dengan pendahulunya, EfficientNetV2 menawarkan peningkatan signifikan dalam kecepatan pelatihan dan efisiensi komputasi, sambil tetap mempertahankan, bahkan meningkatkan, performa akurasi [12]. Salah satu inovasi utama dalam EfficientNetV2 adalah penggunaan compound scaling, yaitu teknik penskalaan yang mengatur secara seimbang antara kedalaman jaringan (depth), lebar jaringan (width), dan resolusi input citra (resolution)[13]. Pendekatan arsitektural ini menghasilkan model yang optimal baik dari segi ukuran maupun performa. Salah satu inovasi utama pada EfficientNetV2 adalah penggunaan blok Fused-MBConv, yang merupakan pengembangan dari blok MBConv pada versi sebelumnya. Blok ini mengintegrasikan beberapa operasi konvolusi ke dalam satu kesatuan yang lebih efisien, sehingga mempercepat proses pelatihan model. Gambar 5.berikut menyajikan struktur arsitektur dari model EfficientNetV2.

```
import os, numpy as np, tensorflow as tf
from tensorflow.keras import layers, Model, regularizers
from tensorflow.keras.applications import EfficientNetV2B0
from tensorflow.keras.losses import CategoricalCrossentropy
from tensorflow.keras.callbacks import EarlyStopping, ReduceLROnPlateau
from tensorflow.keras.optimizers.schedules import CosineDecayRestarts
from kerastuner.tuners import BayesianOptimization
```

Gambar 4. Library yang digunakan



Gambar 5. Arsitektur EfficientNetV2

Dalam penerapannya, model ini menggunakan pendekatan transfer learning, di mana bagian utama dari EfficientNetV2 berfungsi sebagai feature extractor. Model ini dilatih sebelumnya (pre-trained) pada dataset ImageNet, sehingga sudah memiliki kemampuan awal dalam mengenali pola visual umum[14].

2.6 Bayesian Hyperparameter Tuning

Alih-alih grid atau random search yang mahal komputasi, kami memanfaatkan Keras Tuner dengan strategi *Bayesian Optimization* untuk menemukan konfigurasi optimal. Parameter yang dituning mencakup learning rate ($1e-5$ – $1e-3$), dropout rate (0.2–0.5), L2 regularization strength, dan opsi unfreeze_base untuk menentukan apakah sebagian layer backbone di-unfreeze. Objective yang dioptimasi adalah val_accuracy pada subset validation[15]. Proses tuning berjalan selama maksimal 10 trial, masing-masing dengan early stopping internal, sehingga secara adaptif mencari titik optimal dengan jumlah percobaan terbatas.

2.7 Confusion Matrix

Confusion matrix merupakan matriks yang berisi informasi tentang nilai aktual dan prediksi dari sebuah klasifikasi. Confusion matrix sangat berguna untuk mengukur *Recall*, *Precision*, *Accuracy* dan *F1-Score* [16]. Adapun perhitungan confusion matrix dalam permasalahan klasifikasi sebagai berikut:

1. Recall (Sensitivity)

Recall menyatakan dari semua kelas positif, seberapa banyak model memprediksikan dengan benar. Recall dapat dihitung dengan persamaan (1) berikut.

$$Recall = \frac{(TP)}{(TP)+(FN)} \quad (1)$$

2. Precision

Precision menyatakan bahwa dari semua kelas positif yang telah diprediksi model, seberapa banyak yang sebenarnya positif. Precision dapat dihitung dengan persamaan (2) berikut.

$$Precision = \frac{(TP)}{(TP)+(FP)} \quad (2)$$

3. Accuracy

Accuracy (error rate) merupakan tingkat prediksi benar yang dihasilkan oleh model atas kumpulan data. *Accuracy* menyatakan seberapa banyak data yang diprediksi benar dan tidak benar dari keseluruhan data atau seberapa dekat nilai prediksi yang dihasilkan model dengan nilai aktual. *Accuracy* dapat dihitung menggunakan persamaan (3) berikut.

$$Accuracy = \frac{(TP + TN)}{TP+FP+FN+TN} \quad (3)$$

4. F1-Score

Sulit untuk membandingkan model dengan *precision* yang rendah dan *recall* tinggi atau sebaliknya. Sehingga untuk membuatnya sebanding, dapat digunakan F-Score. F1-score membantu mengukur *recall* dan *precision* pada saat yang bersamaan (Narkhede, 2018). *F-Score* dapat dihitung menggunakan persamaan (4) berikut.

$$F - measure = \frac{2 \times recall \times precision}{recall + precision} \quad (4)$$

3. HASIL DAN PEMBAHASAN

3.1 Hasil Proses Training dengan Tuning Hyperparameter Bayesian Optimization

Eksperimen pada penelitian ini dilaksanakan di platform Google Colaboratory dengan (GPU NVIDIA T4 16 GB; Python 3.10, TensorFlow 2.15/Keras 2.15, Keras-Tuner 1.4.x) serta tuning *hyperparameter Bayesian Optimization* dengan 10 kali percobaan dengan kombinasi “unfreeze_base”, dropout, dan learning rate yang berbeda. Pada setiap trial, model EfficientNetV2 di-compile dengan loss CategoricalCrossentropy (label smoothing 0.1) dan di-train selama 10 epoch, dengan callback EarlyStopping (patience = 5) dan ReduceLROnPlateau (factor = 0.5, patience = 3).

Tabel 2. Parameter Model EfficientNetV2

No	Parameter
1	loss CategoricalCrossentropy (label smoothing 0.1)
2	epoch (10)
3	callback EarlyStopping (patience = 10)
4	ReduceLROnPlateau (factor = 0.5, patience = 3)

Tabel 3. Hasil val_accuracy per trial Bayesian Optimization

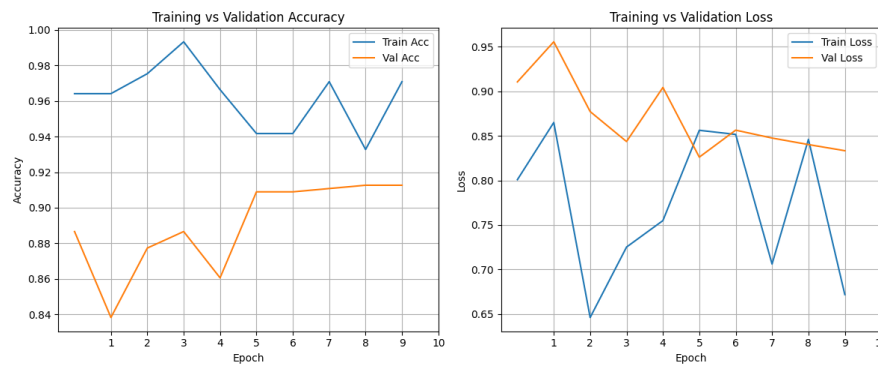
Trial	unfreeze_base	Dropout	Learning Rate	val_accuracy
1	False	0.4	9.0636×10^{-5}	0.64498
2	False	0.2	4.1601×10^{-4}	0.88476
3	False	0.2	3.9935×10^{-4}	0.89591
4	True	0.2	1.4772×10^{-4}	0.86617
5	True	0.4	5.0572×10^{-5}	0.89591
6	False	0.2	8.4688×10^{-4}	0.90335

Trial	unfreeze_base	Dropout	Learning Rate	val_accuracy
7	False	0.4	6.3609×10^{-4}	0.87546
8	False	0.2	9.4036×10^{-5}	0.62639
9	False	0.4	2.2058×10^{-5}	0.15799
10	True	0.2	3.7298×10^{-4}	0.92751

Penalaan (tuning) hiperparameter dilakukan dengan *Bayesian Optimization* sebanyak 10 percobaan pada tiga komponen utama: kondisi backbone (dibuka/tidak), dropout, dan learning rate. Setiap percobaan melatih EfficientNetV2 selama 10 epoch dengan CategoricalCrossentropy ber-label smoothing 0,1 serta callbacks EarlyStopping (patience 5) dan ReduceLROnPlateau (factor 0,5; patience 3). Hasilnya menunjukkan pola yang jelas: learning rate menengah sekitar $3-5 \times 10^{-4}$ secara konsisten menghasilkan akurasi validasi tinggi, sedangkan learning rate terlalu kecil ($\sim 10^{-5}$) gagal mendorong konvergensi. Dropout 0,2 terbukti lebih stabil dan akurat dibanding 0,4 yang cenderung terlalu membatasi kapasitas model. Membuka (unfreeze) backbone bermanfaat jika dipadukan dengan learning rate yang tepat; tanpa kombinasi tersebut keuntungannya tidak terlihat. Konfigurasi terbaik—unfreeze backbone, dropout 0,2, dan learning rate $3,73 \times 10^{-4}$ —mencapai akurasi validasi 0,9275 dan dipakai untuk pelatihan akhir, yang menghasilkan akurasi uji 97%. Secara keseluruhan, *Bayesian Optimization* menemukan pengaturan efektif hanya dengan 10 percobaan, sehingga lebih efisien dibanding penalaan manual atau grid/random search.

3.4 Hasil Evaluasi Model

Evaluasi model terhadap model klasifikasi jenis ikan dilakukan untuk menilai sejauh mana model mampu mengenali dan membedakan fitur vitur dari setiap kelas ikan. Gambar 6. menampilkan perbandingan antara akurasi dan loss pada data pelatihan (train) serta validasi (val) selama 10 epoch training model. Pada grafik sebelah kiri (Training vs Validation Accuracy), terlihat bahwa akurasi data pelatihan cenderung stabil dan tinggi, berkisar antara 94% hingga hampir 99%. Sementara itu, akurasi validasi menunjukkan peningkatan secara bertahap, dimulai dari sekitar 88% pada awal epoch dan meningkat menjadi sekitar 91% pada akhir epoch ke-10. Hal ini mengindikasikan bahwa model mampu belajar dengan baik dan generalisasi ke data validasi juga cukup baik, tanpa terjadi overfitting yang ekstrim.



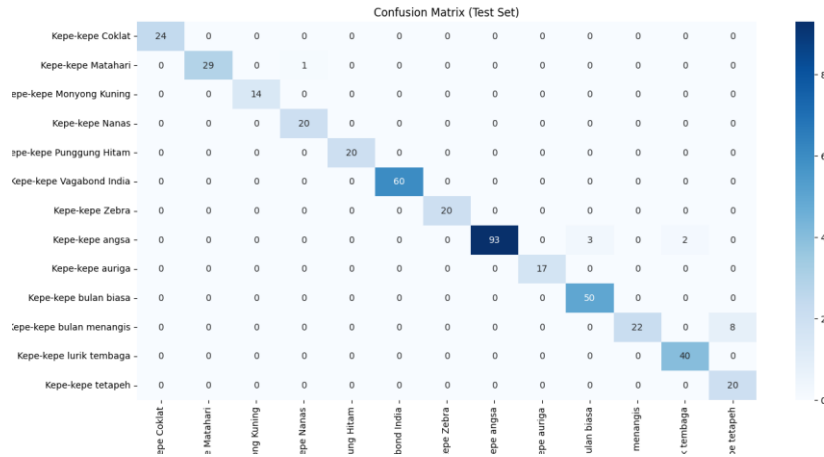
Gambar 6. Perbandingan Akurasi dan Loss

Pada grafik sebelah kanan (Training vs Validation Loss), pola loss data pelatihan secara umum mengalami fluktuasi, namun menunjukkan tren penurunan, khususnya setelah epoch kedua. Sementara itu, loss pada data validasi juga cenderung menurun, meskipun terdapat sedikit fluktuasi dari epoch ke epoch. Penurunan loss pada kedua dataset ini menandakan bahwa proses optimasi model berjalan efektif, meskipun fluktuasi kecil masih terlihat, yang merupakan hal umum pada proses training deep learning[17]. Secara keseluruhan, kedua grafik menunjukkan bahwa model memiliki performa yang cukup stabil, dengan akurasi validasi yang terus meningkat dan loss validasi yang menurun. Hal ini menandakan bahwa model tidak mengalami overfitting berat, dan proses training berjalan secara efektif hingga 10 epoch[18]. Hasil evaluasi divisualisasikan dalam wujud confusion matrix seperti ditunjukkan dalam Gambar 7.

Tabel 4. Jumlah Data Uji

Kelas	Jumlah
Kepe-kepe Coklat	24
Kepe-kepe Matahari	30
Kepe-kepe Monyong Kuning	14
Kepe-kepe Nanas	20
Kepe-kepe Punggung Hitam	20
Kepe-kepe Vagabond India	60

Kepe-kepe Zebra	20
Kepe-kepe angsa	98
Kepe-kepe auriga	17
Kepe-kepe bulan biasa	50
Kepe-kepe bulan menangis	30
Kepe-kepe lurik tembaga	40
Kepe-kepe tetapeh	20



Gambar 7. Confusion Matrix Multikelas

Tabel 5. Hasil Precision, Recall dan F1-Score Tiap Kelas

Kelas	Precision	Recall	F1-score
Kepe-kepe Coklat	100%	100%	100%
Kepe-kepe Matahari	100%	97%	98%
Kepe-kepe Monyong Kuning	100%	100%	100%
Kepe-kepe Nanas	95%	100%	98%
Kepe-kepe Punggung Hitam	100%	100%	100%
Kepe-kepe Vagabond India	100%	100%	100%
Kepe-kepe Zebra	100%	100%	100%
Kepe-kepe angsa	100%	95%	97%
Kepe-kepe auriga	100%	100%	100%
Kepe-kepe bulan biasa	94%	100%	97%
Kepe-kepe bulan menangis	100%	73%	85%
Kepe-kepe lurik tembaga	95%	100%	98%
Kepe-kepe tetapeh	71%	100%	83%
Akurasi		97.00%	

Peningkatan kinerja yang diperoleh dapat dijelaskan oleh kombinasi rancangan metode. EfficientNetV2 menyediakan kapasitas representasi yang efisien pada resolusi 224×224 sehingga detail tekstur dan pola garis pada Chaetodontidae (*Butterflyfishes*) dapat dipelajari tanpa biaya komputasi berlebihan. *Bayesian Optimization* mengarahkan pencarian ke wilayah hiperparameter yang tepat khususnya laju belajar menengah sekitar $3,7 \times 10^{-4}$, dropout 0,2, dan *fine-tuning* backbone terpilih sehingga keseimbangan bias varians tercapai hanya dengan 10 percobaan. MixUp memberi hasil spesifik karena ia mengubah distribusi pelatihan dari sampel “titik” menjadi kombinasi konveks antar-kelas (citra dan label), sehingga model didorong untuk berperilaku linier di ruang fitur di antara dua kelas. Efek langsungnya mirip label smoothing adaptif: batas keputusan menjadi lebih halus, model kurang gemar menghafal artefak lokal (refleksi kaca, noise latar), dan varian validasi menurun. Pada dataset ikan kepe-kepe yang sarat kemiripan visual (pola garis/ocellus), hal ini meningkatkan ketahanan terhadap overfitting dan membantu kelas minor karena tiap mini-batch memproduksi variasi baru dari kombinasi sampel. Namun sifatnya yang “mengaburkan” tepi keputusan juga bisa menurunkan ketajaman ciri halus—khususnya bila dua kelas benar-benar berdekatan secara morfologi. Itulah mengapa pada kasus seperti Bulan Menangis vs Lurik Tembaga Anda masih melihat kebingungan interpolasi intens (α terlalu besar atau frekuensi pemakaian terlalu tinggi) cenderung “melunakkan” perbedaan mikro yang justru diperlukan untuk memisahkan pasangan mirip. Dengan kata lain, MixUp menaikkan stabilitas dan recall pada banyak kelas, tetapi berisiko mengorbankan presisi pada pasangan yang nyaris serupa; karenanya pemilihan $\alpha \approx 0,2$ (rendah–menengah) dan kombinasi dengan CutMix tepat untuk menjaga keseimbangan antara “pelapisan” global dan penekanan area lokal yang informatif.

Sementara itu, *Bayesian hyperparameter* tuning menghasilkan pola kinerja spesifik karena ia mempelajari peta kasar antara konfigurasi (LR, dropout, kedalaman unfreeze) dan metrik validasi, lalu menyeimbangkan eksplorasi–eksploitasi pada area yang menjanjikan. Dalam konteks transfer learning EfficientNetV2, ditemukannya LR menengah ($\sim 3,7 \times 10^{-4}$) dan dropout 0,2 bukan kebetulan: LR terlalu kecil gagal keluar dari basin awal (konvergensi lambat/mandek), sedangkan LR terlalu besar mendorong catastrophic forgetting saat backbone di-unfreeze. Dropout 0,2 memberi regularisasi cukup untuk ukuran data Anda; 0,4 cenderung over-regularize sehingga kapasitas representasi turun (terlihat dari val-accuracy yang lebih fluktuatif/rendah). Tautan kausal ini diperkuat oleh interaksi dengan unfreeze: membuka sebagian backbone baru memberi manfaat hanya bila LR cukup untuk menyesuaikan bobot pralatih tanpa merusak fitur generik ImageNet. Karena ruang pencarian Anda berdimensi rendah dan dievaluasi dengan early stopping, 10 trial sudah memadai bagi BO untuk memusat pada “wilayah manis” tersebut—itulah sebabnya konfigurasi terbaik muncul cepat, sekaligus menghemat eksperimen dibanding grid/random search. Implikasinya, keberhasilan MixUp dan *Bayesian* tuning di dataset ini terjadi karena keduanya mengontrol bias varians dari arah berbeda: MixUp menurunkan varians (lebih tahan noise/artefak dan ketimpangan), sedangkan *Bayesian* tuning menurunkan bias pengaturan (menempatkan LR–dropout–unfreeze pada rezim yang tepat untuk fine-tuning EfficientNetV2). Kinerja tinggi (akurasi uji 97%, F1 rata-rata >95%) lahir dari sinergi tersebut. Untuk meningkatkan kelas paling sulit, Anda dapat menurunkan intensitas MixUp (α) pada pasangan yang sangat mirip, menaikkan porsi CutMix terarah pada region diagnostik, dan menjadikan macro-F1 (bukan hanya val-accuracy) sebagai objektif BO agar proses penalaan lebih selaras dengan tujuan pemisahan antar-kelas yang seimbang.

Meskipun demikian, temuan pada Bulan Menangis dan Tetapeh mengindikasikan ruang perbaikan yang spesifik. Peningkatan disarankan melalui augmentasi warna yang lebih kaya (misalnya penyesuaian hue–saturation atau CLAHE) untuk mengatasi pergeseran pencahayaan dan membuat batas antar kelas yang mirip lebih tegas dan penanganan ketimpangan melalui class-balanced atau focal loss untuk menekan lonjakan false positive serta pendekatan berbasis segmentasi atau ROI agar perhatian model terfokus pada tubuh ikan dan tidak terpengaruh refleksi kaca atau latar. Validasi stabilitas juga akan lebih kuat bila ditambahkan replikasi k-fold atau beberapa stratified split dengan interval kepercayaan, sehingga performa yang dilaporkan tidak bergantung pada satu partisi data. Secara keseluruhan, hasil evaluasi mendukung bahwa kombinasi EfficientNetV2, penalaan *Bayesian*, dan augmentasi–regularisasi yang tepat merupakan pilihan efektif untuk dataset ikan kepe-kepe ini, dengan peningkatan terutama terjadi karena pengaturan hiperparameter yang selaras dengan karakter visual dan ketimpangan kelas pada data.

3.4 Perbandingan dengan Penelitian Sebelumnya

Untuk menempatkan kinerja model yang diusulkan dalam konteks state-of-the-art, Tabel 6. merangkum beberapa studi relevan beserta metode dan akurasi. Perbandingan ini dimaksudkan sebagai pemosisian metodologis, bukan uji tanding langsung, karena kemungkinan perbedaan dataset, protokol pembagian data, dan métrik evaluasi yang digunakan pada masing-masing penelitian.

Tabel 6. Kajian Studi Relevan

Judul	Metode	Akurasi
Improving <i>Butterfly</i> Fish Image Classification Accuracy using HSV Feature Extraction and SMOTE-Based Data Balancing[19]	KNN dan Smote	87.59%
MobileNets-V1 Architecture for Web Based Fish Image Classification[20]	MobileNets-V1	89.00%
Underwater Fish Species Classification using Convolutional Neural Network and Deep Learning[21]	Convolutional Neural Network	96.29%
Peningkatan Akurasi Klasifikasi Ikan kepe-kepe (<i>Famili Chaetodontidae</i>) dengan EfficientNetV2 dan <i>Bayesian Hyperparameter Tuning</i>	EfficientNetV2 dan <i>Bayesian Hyperparameter Tuning</i>	97.00%

1. *Improving Butterfly Fish Image Classification Accuracy using HSV Feature Extraction and SMOTE* — KNN + SMOTE (87,59%). Mengandalkan fitur buatan (HSV) dan oversampling sintetis; pendekatan ini cenderung

kurang menangkap pola morfologi/tekstur halus dan rentan terhadap distorsi warna, sehingga akurasi berada di kisaran menengah.

2. *MobileNets-V1 Architecture for Web Based Fish Image Classification* — MobileNetV1 (89,00%). Arsitektur ringan untuk aplikasi web, namun tanpa penalaan hiperparameter adaptif dan augmentasi lanjutan, sehingga kapasitas generalisasi terbatas pada variasi pose/pencahayaan.
3. *Underwater Fish Species Classification using CNN and Deep learning* — CNN (96,29%). Jaringan konvolusional umum pada citra bawah air menunjukkan kinerja tinggi; meskipun demikian, detail strategi penalaan dan pengendalian ketidakseimbangan kelas umumnya tidak dilaporkan secara eksplisit.
4. Usulan Model -EfficientNetV2 + *Bayesian Hyperparameter Tuning* (97,00%). Peningkatan akurasi dicapai melalui *scaling* adaptif EfficientNetV2, tuning Bayes (10 *trial* sehingga lebih hemat eksperimen dibanding *grid/random search*), serta MixUp–CutMix, label smoothing, dropout, dan L2 yang memperkuat generalisasi pada kelas minor. Secara numerik, capaian ini unggul +9,41 poin terhadap KNN+SMOTE, +8,00 poin atas MobileNetV1, dan +0,71 poin di atas CNN umum.

Dengan demikian, pendekatan yang diusulkan menunjukkan kinerja setara/lebih tinggi dengan biaya tuning yang lebih efisien, serta rancangan augmentasi-regularisasi yang lebih sistematis untuk menghadapi kompleksitas citra ikan karang.

4. KESIMPULAN

Penelitian ini menghadirkan pipeline klasifikasi spesies ikan kepe-kepe (Chaetodontidae) berbasis EfficientNetV2 yang dipadukan dengan *Bayesian Hyperparameter Tuning* (10 *trial*) untuk mencapai akurasi tinggi sekaligus efisiensi penalaan. Integrasi teknik augmentasi lanjutan (MixUp, CutMix) serta regularisasi (dropout, label smoothing, dan L2) dirancang spesifik guna menghadapi kemiripan antarkelas dan ketimpangan distribusi. Konfigurasi terbaik—*unfreeze backbone*, dropout 0,2, dan learning rate $\approx 3,7 \times 10^{-4}$ —mencapai *val-accuracy* 92,75% dan akurasi uji 97% pada 13 kelas, dengan precision serta recall rata-rata di atas 95%, menegaskan keunggulan *Bayesian* dibanding penalaan manual/grid pada data dengan variasi pose, pencahayaan, dan artefak latar. Keterbatasan utama terletak pada masih adanya kelas minoritas yang kurang terwakili dan potensi bias akibat refleksi kaca/objek latar yang memengaruhi ekstraksi fitur. Ke depan, peningkatan dapat difokuskan pada penambahan data kelas minor, penerapan class-balanced/focal loss, eksplorasi backbone yang lebih ringan untuk perangkat lapangan, dan integrasi segmentasi/ROI agar perhatian model tepat pada objek, disertai uji lintas domain (dari akuarium ke habitat alam ikan) serta kalibrasi probabilitas untuk kesiapan deployment. Secara keseluruhan, temuan ini membuktikan bahwa kombinasi arsitektur efisien dan penalaan adaptif menghasilkan sistem identifikasi–monitoring ikan yang andal dan hemat sumber daya, sekaligus memberikan landasan kuat bagi penguatan konservasi dan riset keanekaragaman hayati laut Indonesia.

REFERENCES

- [1] A. Nuryanto, DIAN BHAGAWATI, and KUSBIYANTO, “Evaluation of conservation and trade status of marine ornamental fish harvested from Pangandaran Coastal Waters, West Java, Indonesia,” *Biodiversitas*, vol. 21, no. 2, Jan. 2020, doi: 10.13057/biodiv/d210212.
- [2] J. P. Nowicki, L. A. O’Connell, P. F. Cowman, S. P. W. Walker, D. J. Coker, and M. S. Pratchett, “Variation in social systems within Chaetodon *butterflyfishes*, with special reference to pair bonding,” *PLoS One*, vol. 13, no. 4, p. e0194465, Apr. 2018, doi: 10.1371/journal.pone.0194465.
- [3] L. Mutawalli, M. T. A. Zaen, and Y. Yuliadi, “Komparasi CNN dengan ResNet Untuk Klasifikasi Paling Akurat Tingkat Keganasan Diabetes Berdasarkan Citra Retinopathy,” *Journal of Computer System and Informatics (JoSYC)*, vol. 4, no. 3, pp. 522–529, May 2023, doi: 10.47065/josyc.v4i3.3248.
- [4] A. Mohammadisabet, R. Hasan, V. Dattana, S. Mahmood, and S. Hussain, “CNN-Based *Optimization* for Fish Species Classification: Tackling Environmental Variability, Class Imbalance, and Real-Time Constraints,” *Information*, vol. 16, no. 2, p. 154, Feb. 2025, doi: 10.3390/info16020154.
- [5] M. Mathur and N. Goel, “FishResNet: Automatic Fish Classification Approach in Underwater Scenario,” *SN Comput Sci*, vol. 2, no. 4, p. 273, Jul. 2021, doi: 10.1007/s42979-021-00614-8.
- [6] M. F. Hanifa *et al.*, “Fishku Apps: Fishes Freshness Detection Using CNN With MobilenetV2,” *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 17, no. 1, p. 67, Feb. 2023, doi: 10.22146/ijccs.80049.
- [7] K. Kurniawan, A. Perdana Windarto, and S. Solikhun, “Refining CNN architecture for forest fire detection: improving accuracy through efficient *hyperparameter* tuning,” *Bulletin of Electrical Engineering and Informatics*, vol. 14, no. 2, pp. 1202–1211, Apr. 2025, doi: 10.11591/eei.v14i2.8805.
- [8] H. Cho, Y. Kim, E. Lee, D. Choi, Y. Lee, and W. Rhee, “Basic Enhancement Strategies When Using *Bayesian Optimization* for *Hyperparameter* Tuning of Deep Neural Networks,” *IEEE Access*, vol. 8, pp. 52588–52608, 2020, doi: 10.1109/ACCESS.2020.2981072.

- [9] A. Susilawati, A. Sh. M. Al-Obaidi, A. Abduh, F. S. Irwansyah, and A. B. D. Nandiyanto, "How to do research methodology: From Literature Review, Bibliometric, Step-by-step Research Stages, to Practical Examples in Science and Engineering Education," *Indonesian Journal of Science and Technology*, vol. 10, no. 1, pp. 1–40, Jan. 2025, doi: 10.17509/ijost.v10i1.78637.
- [10] C. Cao, F. Zhou, Y. Dai, J. Wang, and K. Zhang, "A Survey of Mix-based Data Augmentation: Taxonomy, Methods, Applications, and Explainability," *ACM Comput Surv*, vol. 57, no. 2, pp. 1–38, Feb. 2025, doi: 10.1145/3696206.
- [11] H. Pan, Y. Guo, M. Yu, and J. Chen, "Enhanced Long-Tailed Recognition With Contrastive CutMix Augmentation," *IEEE Transactions on Image Processing*, vol. 33, pp. 4215–4230, 2024, doi: 10.1109/TIP.2024.3425148.
- [12] D. Liu, W. Wang, X. Wu, and J. Yang, "EfficientNetv2 Model for Breast Cancer Histopathological Image Classification," *2022 3rd International Conference on Electronic Communication and Artificial Intelligence (IWECAI)*, pp. 384–387, Jan. 2022, doi: 10.1109/IWECAI55315.2022.00081.
- [13] M. Hayat, N. Ahmad, A. Nasir, and Z. Ahmad Tariq, "Hybrid *Deep learning* EfficientNetV2 and Vision Transformer (EffNetV2-ViT) Model for Breast Cancer Histopathological Image Classification," *IEEE Access*, vol. 12, pp. 184119–184131, 2024, doi: 10.1109/ACCESS.2024.3503413.
- [14] L. Jiang, S. Zhu, and N. Sun, "An Improved Lightweight Variant of EfficientNetV2 Coupled With Sensor Fusion and Transfer Learning Techniques for Motor Fault Diagnosis," *IEEE Access*, vol. 12, pp. 84470–84487, 2024, doi: 10.1109/ACCESS.2024.3412050.
- [15] A. H. Victoria and G. Maragatham, "Automatic tuning of *hyperparameters* using *Bayesian Optimization* ," *Evolving Systems*, vol. 12, no. 1, pp. 217–223, Mar. 2021, doi: 10.1007/s12530-020-09345-2.
- [16] M. Heydarian, T. E. Doyle, and R. Samavi, "MLCM: Multi-Label Confusion Matrix," *IEEE Access*, vol. 10, pp. 19083–19095, 2022, doi: 10.1109/ACCESS.2022.3151048.
- [17] E. Zhang, R. Zhong, M. Munetomo, and M. Wahib, "Validation Loss Landscape Exploration with Deep Q-Learning," in *2024 International Joint Conference on Neural Networks (IJCNN)*, IEEE, Jun. 2024, pp. 1–9. doi: 10.1109/IJCNN60899.2024.10651182.
- [18] M. M. Bejani and M. Ghatte, "A systematic review on overfitting control in shallow and deep neural networks," *Artif Intell Rev*, vol. 54, no. 8, pp. 6391–6438, Dec. 2021, doi: 10.1007/s10462-021-09975-1.
- [19] I. P. A. Putra, I. M. A. Wirawan, and I. G. A. Gunadi, "Improving *Butterfly* Fish Image Classification Accuracy using HSV Feature Extraction and SMOTE-Based Data Balancing," *INOVTEK Polbeng - Seri Informatika*, vol. 10, no. 3, pp. 1402–1411, Aug. 2025, doi: 10.35314/vw52nn48.
- [20] Herlambang Duwi Prasetyo, Pandu Ananto Hogantara, and Ika Nurlaili Isnainiyah, "MobileNets-V1 Architecture for Web Based Fish Image Classification," *Data Science: Journal of Computing and Applied Informatics*, vol. 5, no. 2, pp. 60–70, Jul. 2021, doi: 10.32734/jocai.v5.i2-6291.
- [21] D. Rathi, S. Jain, and S. Indu, "Underwater Fish Species Classification using Convolutional Neural Network and *Deep learning*." [Online]. Available: <http://dhrivrathi.me/http://www.dtu.ac.in/Web/Departments/Electronics/faculty/sindu.php>