

# OPTIMALISASI ARSITEKTUR DEEP-LEARNING UNTUK OTOMATISASI KLASIFIKASI IDENTIFIKASI SPESIES IKAN

Saeful Bahri <sup>1</sup>, Satia Suhada <sup>2</sup>, Rusda Wajhillah <sup>3</sup>

<sup>1,2,3</sup> Universitas Bina Sarana Informatika Kampus Kota Sukabumi  
Jl. Cemerlang no. 8 Sukakarya, Sukabumi, 6251992

[saeful.sel@bsi.ac.id](mailto:saeful.sel@bsi.ac.id) <sup>1</sup>, [satia.shq@bsi.ac.id](mailto:satia.shq@bsi.ac.id) <sup>2</sup>, [rusda.rwh@bsi.ac.id](mailto:rusda.rwh@bsi.ac.id) <sup>3</sup>

## Abstract

*This research discusses the optimization of deep learning architecture for automating fish classification through images with various backgrounds and diverse lighting conditions. Several previous studies on fish species classification have been conducted by researchers worldwide using various methods, including Naive Bayes, CNN, and deep learning networks. In this study, three deep learning architectures (ResNet101v2, CoAtNet-0, and EfficientNetV2B0) will be compared with three optimization algorithms (Adam, SGD, and MSProp) to determine the best architecture for the deep learning model in automating fish species identification. The dataset consists of 3,248 images divided into eight species classes. The results of the model testing showed that ResNet101v2 optimized by Adam had the highest accuracy value compared to the other two architectures, with an accuracy rate of 62%.*

**Keywords:** CNN, Deep Learning, Clasification, Fish

## Abstrak

*Penelitian ini membahas tentang optimalisasi arsitektur pada deep Learning untuk otomatisasi klasifikasi ikan melalui citra dengan berbagai macam latar belakang dan kondisi cahaya yang beragam. Beberapa riset terdahulu tentang klasifikasi spesies ikan telah dilakukan oleh beberapa peneliti di dunia menggunakan berbagai metode, termasuk Naïve bayes, CNN, dan jaringan deep learning. Dalam penelitian ini, akan dibandingkan tiga arsitektur deep learning (ResNet101v2, CoAtNet-0, dan EfficientNetV2B0) dengan tiga algoritma optimasi (Adam, SGD, dan MSProp) untuk mengetahui arsitektur yang terbaik untuk model deep learning pada otomatisasi identifikasi spesies ikan, yang terdiri dari 3.248 citra yang terbagi menjadi delapan kelas spesies, hasil dari pengujian model didapat bahwa ResNet101v2 yang dioptimalisasi oleh Adam memiliki nilai akurasi paling tinggi dibanding 2 Arsitektur lainnya sebesar 62% .*

**Kata kunci:** CNN, Deep Learning, Klasifikasi, Ikan

## 1. PENDAHULUAN

Identifikasi ikan secara manual akan memerlukan waktu yang panjang, selain waktu yang panjang pengalaman dan pengetahuan sangat diperlukan dalam proses identifikasi ikan, terlebih terdapat jenis ikan yang secara spesies identik. Kita dapat mengenali spesies ikan hanya dengan melihat ciri fisik seperti warna, motif, bentuk tubuh dan kontur kulit ikan tersebut. Pengembangan sistem otomatisasi klasifikasi ikan melalui citra dengan berbagai macam latar belakang dan kondisi cahaya yang beragam menjadi tantangan tersendiri.

Beberapa riset terdahulu tentang klasifikasi spesies ikan telah dilakukan oleh beberapa peneliti di dunia, sebagai contoh penelitian yang menerapkan Naïve bayes dan jaringan deep learning untuk melakukan klasifikasi multi segment pada ikan di industri aquakultur [1], penerapan CNN dalam melakukan klasifikasi ikan [2], penerapan Multi-level residual network VGGNet untuk klasifikasi ikan[3], Deep convolutional auto encoder dalam klasifikasi ikan genus Carper[4], Deteksi otomatis klasifikasi ikan dengan deep learning [5].

Beberapa algoritma tersebut bekerja optimal dengan menggabungkan dua objek minor. Diantara objek minor tersebut adalah fitur yang terdapat pada ikan itu sendiri diantaranya sudut, texture untuk menggambarkan tulang, tutup insang dan tekstur kulit. Selain fitur minor tersebut beberapa fitur mayor dapat membantu dalam proses klasifikasi ikan seperti kepala, ekor dan beberapa bagian tubuh lainnya. Oleh sebab itu, objek minor dan mayor dapat menjanjikan kinerja yang tinggi dalam proses pengembangan sistem klasifikasi. Meskipun demikian pendekatan berbasis fitur buatan membutuhkan usaha lebih jauh, terkait dengan pre-processing data seperti deteksi anomali, normalisasi data, penanganan data yang salah dan penentuan fitur.

Salah satu model pendekatan berbasis *non-hand-crafted features-based* adalah algoritma CNN (*Convolutional Neural Network*) yang memiliki kelebihan dalam melakukan ekstraksi fitur secara implisit. Langkah ini dimasukan secara langsung kedalam blok konvolusional dari blok awal sampai blok akhir menggunakan teknik konvolusi tertentu. Blok-blok konvolusi tersebut masing-masing menghasilkan fitur minor, menengah dan fitur mayor. Penelitian yang terkait dengan pendekatan ini adalah penelitian tentang klasifikasi spesies ikan[6], dataset yang digunakan dalam penelitian tersebut merupakan jenis ikan karper. CNN juga digunakan dalam melakukan klasifikasi ikan dan object bukan ikan dalam aliran sungai [2] dalam penelitian tersebut algoritma untuk membangun model klasifikasi menggunakan CNN mendapatkan tingkat akurasi 99.3%. Deteksi ikan dilakukan dengan mengambil sebanyak 400 video pada aliran sungai. CNN juga digunakan dalam otomatisasi identifikasi jenis nematoda yang menjadi parasite dalam tanaman [7], klasifikasi ionisasi [8], deteksi dan klasifikasi penuaan[9] klasifikasi dan perhitungan ikan [10].

Penelitian sebelumnya menggunakan dataset public dari *fishdataset* yang berisi 60% ikan yang hidup di air asin. Dalam penelitian[3] hanya menerapkan model VGGNet dalam proses klasifikasinya, sedangkan pada penelitian ini dataset yang digunakan ditambahkan dari dataset hasil penelitian[3] dengan 8 spesies ikan yang telah teridentifikasi. Dataset spesies ikan tersebut akan digunakan untuk proses training data. Kemudian dalam penelitian ini kami akan membandingkan 3 arsitektur deep learning diantaranya *ResNet101v2*, *CoAtNet-0* dan *EfficientNetV2B0* dengan penambahan 3 optimizer. Yang bertujuan untuk melihat sejauh mana pengaruh algoritma optimasi terhadap nilai akurasi hasil klasifikasi dari arsitektur dalam model deep learning. Setelah itu dilakukan evaluasi kinerja dari ke tiga 3 arsitektur deep learning yang telah ditambahkan beberapa algoritma optimasi diantaranya Adam, SGD dan MSProp. Setelah model terbentuk, maka diketahuilah arsitektur terbaik yang tepat digunakan untuk model deep learning pada otomatisasi identifikasi spesies ikan

## 2. METODOLOGI PENELITIAN

### 2.1. Metode Pengumpulan Data

Semua data yang digunakan pada penelitian ini merupakan ikan yang umum dikonsumsi oleh masyarakat pada umumnya dan tersebar hampir di seluruh wilayah Indonesia. Dataset tersebut diambil dari <https://data.mendeley.com/datasets/76cr3wfhff/1>. Dataset publik tersebut berjumlah 3.248 baris yang terbagi kedalam 8 kelas spesies ikan diantaranya *Chanos-chanos* Sebanyak 500 Citra, *Eleutheronema Tetradactylum* sebanyak 240 Citra, *Johnius Trachycephalus* sebanyak 240 Citra, *Nibea Albiflora* sebanyak 252 Citra, *Oreochromis Mossambicus* sebanyak 331 Citra, *Oreochromis Niloticus* sebanyak 564 Citra, serta sisanya dari spesies *Rastrelliger Faughni* dan *Upeneus Moluccensis*.

### 2.2. Pengolahan Data

Data sample yang diperoleh kemudian diproses dengan metode serupa yang digunakan dalam penelitian [7]. Sample dipangkas berdasarkan deteksi tepi dalam upaya menyamakan ukuran citra, hal ini digunakan untuk mengurangi *noise* informasi yang berlebihan. Selanjutnya sample diubah menjadi gambar dengan skala 224x224 agar sesuai dengan skala model uji gambar dapat dilihat pada gambar 1 di bawah ini.



Gambar 1. Data Spesies Ikan

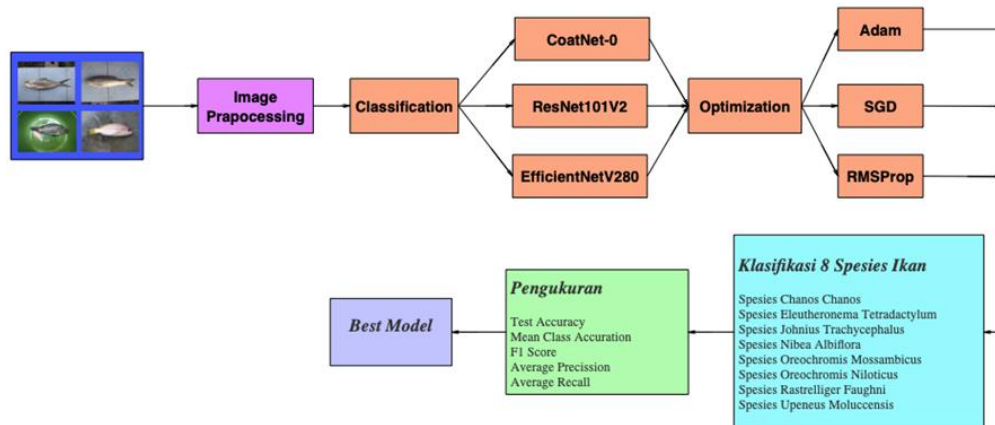
Citra ikan tersebut didistribusikan ke dalam 8 class yang dapat dilihat pada tabel 1.

Tabel 1. Distribusi Jenis Ikan dalam Dataset

<b>Genus</b>	<b>Jumlah Sample</b>
<i>Upeneus Moluccensis</i>	577
<i>Oreochromis Niloticus</i>	564
<i>Rastrelliger Faughni</i>	544
<i>Chanos Chanos</i>	500
<i>Oreochromis Mossambicus</i>	331
<i>Nibea Albiflora</i>	252
<i>Eleutheronema Tetradactylum</i>	240
<i>Johnius Trachycephalus</i>	240

### 2.3. Usulan Penelitian

Pada penelitian ini kami mengajukan 3 arsitektur deep-learning yang telah dioptimalkan oleh algoritma 3 optimasi yakni Adam, SGD dan RMSProp. pada gambar 2 terdapat gambaran umum alur kerangka penelitian ini. Langkah pertama, dataset ikan dikumpulkan serta diklasifikasikan ke dalam beberapa kelas. Setelah itu dilakukan *pra-processing* data dengan menggunakan teknik deteksi tepi, pemotongan dan konversi skala abu-abu. Untuk meningkatkan ukuran dataset, dilakukan augmentasi tunggal seperti pembalikan gambar, penambahan noise, pengaburan gambar, pencerahan, dan penambahan kontras. Tahap selanjutnya, foto-foto tersebut digunakan sebagai input untuk melatih model dengan beberapa augmentasi dan kombinasi fungsi optimasi. Kinerja model diukur dan dianalisis dengan menggunakan metrik tertentu dan disimpulkan model mana yang terbaik.



Gambar 2. Kerangka Penelitian

## 2.4. Arsitektur Deep Learning

Klasifikasi ikan dilakukan menggunakan beberapa model terbaru dalam masalah klasifikasi gambar yaitu ResNetV2, CoAtNet dan EfficientNetV2. Model dipilih berdasarkan kinerja mereka pada Klasifikasi Gambar pada ImageNet Benchmark[11]. Dikarenakan terdapat keterbatasan pada perangkat keras dan ukuran dataset yang digunakan dalam eksperimen, maka hanya digunakan beberapa variasi model tertentu seperti ResNet101V2, CoAtNet-0 dan EfficientNetV2B0.

### 2.4.1. ResNet (Residual Network)

Arsitektur Residual Networks (ResNet), merupakan sebuah arsitektur CNN didasarkan pada arsitektur VGG. Arsitektur ini menggunakan pembelajaran residual pada blok-blok pembangunannya dengan menambahkan koneksi yang melompati satu atau beberapa layer dalam arsitektur CNN. Hal ini membantu mengatasi masalah degradasi yang dialami oleh arsitektur VGG ketika model yang lebih dalam digunakan[12]. ResNetV2 adalah versi yang ditingkatkan dari arsitektur ResNet dan meningkatkan kecepatan propagasi data pada setiap blok residual dengan memanfaatkan pemetaan identitas sebagai koneksi melompat dan aktivasi setelah penambahan. Berikut persamaan dari ResNet[13]

$$x_{l+1} = x_l + F(x_l \cdot W_l)$$

Dalam blok residual ke- $l$ ,  $x_l$  dan  $x_{l+1}$  masing-masing mewakili input dan output.  $W_l$  adalah himpunan bobot yang digunakan dalam blok tersebut, dan  $F(x_l \cdot W_l)$  adalah fungsi residual yang menghasilkan perbedaan antara output dan input. Untuk mengimplementasikan persamaan berikutnya, dapat dilakukan shortcut connection dengan memetakan input langsung ke output menggunakan fungsi identitas, atau dengan melewati satu atau lebih lapisan. Hal ini dilakukan secara berulang-ulang untuk setiap blok residual ke- $l$  dalam rangkaian, sehingga menghasilkan efek penggabungan atau

penambahan antara input dan output pada setiap blok tersebut.  $x = x$  sehingga diperoleh nilai L.

$$+\sum^{L-1} F(x \cdot W)$$

#### 2.4.2. CoAtNet (*Convolution and Attention Networks*)

CoAtNet adalah sebuah keluarga model hibrida yang menggabungkan arsitektur CNN dan Transformer untuk meningkatkan kemampuan generalisasi dan kapasitas model. Arsitektur Transformer dengan mekanisme self-attention memiliki kapasitas model yang lebih tinggi dan sangat cocok untuk digunakan pada dataset yang lebih besar dan lebih beragam. Sedangkan arsitektur konvolusional memiliki kemampuan generalisasi yang lebih baik dan kecepatan konvergensi yang lebih cepat. CoAtNet terdiri dari 5 tahap dengan 1 lapisan konvolusional, 2 lapisan MBConv, dan 2 lapisan transformer, yang masing-masing memiliki properti yang berbeda tergantung pada varian model. CoAtNet memiliki 5 variasi dasar (CoAtNet-0 hingga CoAtNet-4) dan 3 variasi lainnya dengan parameter blok yang berbeda (CoAtNet-5 hingga CoAtNet-7)[14].

#### 2.4.3. EfficientNet

Arsitektur dasar EfficientNet menggunakan sebuah metode penskalaan baru yang memperbesar kapasitas model dengan meningkatkan dimensi lebar, kedalaman, dan resolusi model. Penskalaan dilakukan dengan menggunakan koefisien gabungan yang sederhana[15]. Dengan model yang jauh lebih kecil dan konvergensi yang lebih cepat, model baru ini berhasil mencapai performa pada dataset ImageNet.

#### 2.4.4. Teknik Optimalisasi

Pada proses pelatihan, digunakan tiga optimizer yang berbeda untuk menentukan optimizer terbaik untuk setiap jenis model serta meminimalkan keuntungan yang tidak adil dari beberapa model dalam kasus penyesuaian hiperparameter. Optimizer yang digunakan adalah Adam, SGD dan RMSprop. Adam dipilih karena performanya yang lebih baik, SGD dipilih untuk mewakili optimisasi gradien descent dan RMSprop dipilih karena cocok untuk mengoptimalkan masalah non-stasioner dan non-konveks.

#### 2.4.5. Pengukuran Model

Dalam eksperimen ini, digunakan beberapa metrik evaluasi seperti TestAccuracy, F1-score, Weighted F1-score, Average precision, dan recall. TestAccuracy digunakan untuk mengevaluasi akurasi rata-rata model pada seluruh gambar dalam set pengujian. F1-score digunakan ketika distribusi kelas dalam dataset tidak seimbang. Weighted F1-score digunakan untuk mengevaluasi dataset yang tidak seimbang, dan presisi serta recall rata-rata direkam untuk kelengkapan data.

$$Test Accuracy = (TP + TN) / (TP + TN + FP + FN)$$

$$Precision = TP / (TP + FP)$$

$$Recall = TP / (TP + FN)$$

$$F1\ Score = (2 \times Precision \times Recall) / (Precision + Recall)$$

Dalam penelitian ini, metrik evaluasi yang digunakan adalah True Positive (TP), False Positive (FP), True Negative (TN), dan False Negative (FN) untuk mengukur performa model. Selain itu, juga digunakan metrik Mean Class Accuracy [16]. Untuk mengevaluasi akurasi setiap kelas dan menunjukkan apakah model belajar fitur diskriminatif dari setiap kelas dibandingkan dengan model lain. Rumus dari metrik ini diberikan pada persamaan berikut.

$$Mean\ Class\ Accuracy = \frac{1}{c} \sum_{i=1}^c \frac{1}{n} \sum_{j=1}^c a_j^i$$

### 3. HASIL DAN PEMBAHASAN

#### 3.1. Kinerja Model dengan Optimalisasi

##### 3.1.1. Adam Optimizer

Performa model dengan menggunakan optimizer Adam menghasilkan akurasi rata-rata yang cukup tinggi untuk semua model. Optimizer Adam dianggap sangat baik untuk mencapai hasil yang memuaskan tanpa melakukan penyesuaian parameter optimizer sesuai dengan model yang digunakan

##### 3.1.2. SGD Optimizer

Performa model dengan menggunakan optimizer SGD menghasilkan akurasi yang bervariasi. Pada model CoAtNet, optimizer SGD menghasilkan akurasi tertinggi dibandingkan dengan optimizer lain pada dataset tanpa augmentasi. Namun, pada model ResNet101v2 dan EfficientNetv2M, penggunaan SGD optimizer secara signifikan menurunkan akurasi ketika menggunakan dataset yang di-augmentasi. Hal ini diduga karena parameter yang digunakan tidak cocok dengan data yang di-augmentasi. Penurunan performa saat menggunakan data augmentasi menunjukkan bahwa optimizer SGD lebih sensitif terhadap perubahan dalam dataset. Optimizer SGD membutuhkan penyesuaian parameter yang lebih tepat untuk mencapai performa tinggi berdasarkan model dan dataset yang digunakan.


##### 3.1.3. RMSProf Optimizer

Penggunaan optimizer RMSprop menghasilkan akurasi yang berbeda-beda pada setiap model. Pada model ResNet101v2, hasilnya lebih rendah dibandingkan dengan model lain. Namun, model EfficientNetV2M memperoleh hasil yang memuaskan dan memiliki salah satu akurasi tertinggi

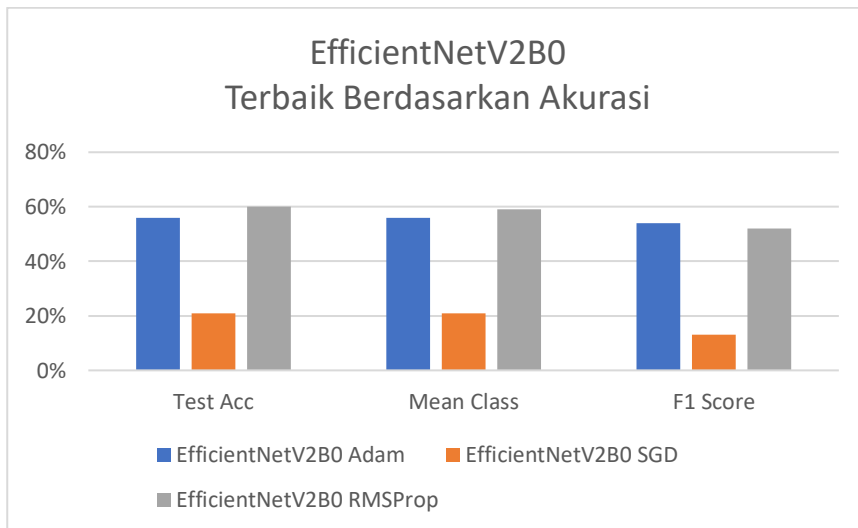
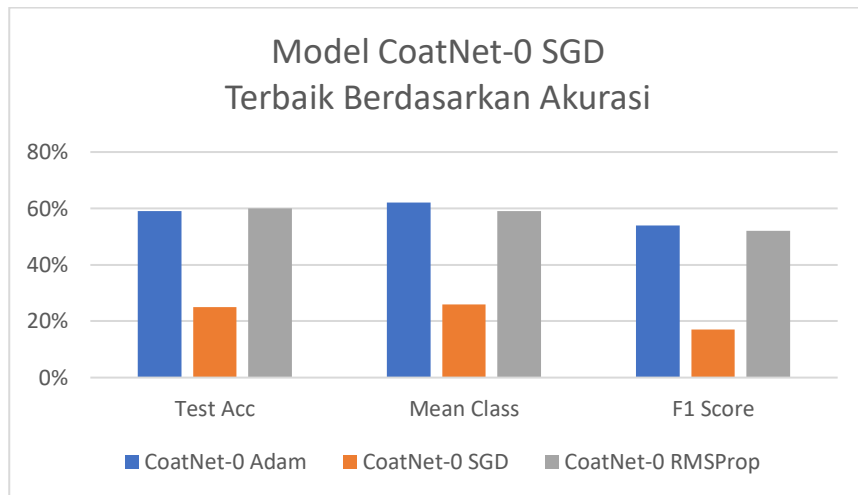
di dalam dataset. Perbedaan ini disebabkan oleh perbedaan nilai parameter yang digunakan di setiap model.

### 3.2. Model Terbaik

Semua data performa model kemudian diurutkan untuk menentukan kombinasi terbaik antara model, optimizer dan augmentasi. Harap diingat bahwa performa model yang diperoleh dari pengujian dapat berbeda dengan aplikasi dunia nyata. Karena jumlah data untuk setiap kelas dalam dataset tidak seimbang, model dengan akurasi pengujian tertinggi tidak selalu memiliki akurasi kelas rata-rata tertinggi. Nilai akurasi kelas rata-rata yang lebih tinggi dapat diinterpretasikan sebagai kemampuan model yang lebih baik untuk mempelajari semua fitur kelas daripada model lain. Tiga model teratas berdasarkan % akurasi pengujian adalah: ResNet50V2 menggunakan Adam; ResNet50V2 menggunakan RMSProp dan ResNet50V2 menggunakan SGD; CoAtNet-0 menggunakan Adam, CoAtNet-0 menggunakan SGD, CoAtNet-0 menggunakan RMSProp, EfficientNetV2B0 menggunakan SGD, EfficientNetV2B0 menggunakan Adam dan EfficientNetV2B0 menggunakan RMSProp. Performa metrik untuk setiap model disajikan dalam Gambar 3. Semua model memiliki performa yang serupa di semua metrik. Dapat disimpulkan bahwa penggunaan berbagai jenis optimasi secara simultan tidak selalu meningkatkan performa model. Optimalisasi ini tidak dapat meningkatkan kemampuan model untuk menggeneralisasi masalah klasifikasi berdasarkan morfologi setiap kelas.







Gambar 3. Hasil Pemodelan dengan Optimalisasi

#### 4. SIMPULAN

Kelayakan model deep learning untuk klasifikasi ikan menggunakan ResNet101V2, CoAtNet-0 dan EfficientNetV2B0 telah dieksplorasi. Teknik deep learning dalam klasifikasi berbasis gambar cukup menjanjikan dan memajukan otomatisasi proses identifikasi ikan. Hasil dari penelitian ini menunjukkan kemampuan penggunaan model deep learning untuk mengidentifikasi ikan yang umum ditemukan. Performa masing-masing model yang diuji memperoleh hasil yang memuaskan. Performa yang luar biasa untuk masing-masing model didapat dengan mengkombinasikan beberapa fungsi optimizer (Adam, SGD dan RSMProp). Berdasarkan varian model yang dipilih (ResNet101v2, CoAtNet0 dan EfficientNetV2B0), model ResNet101V2 memperoleh performa terbaik pada dataset yang digunakan, dengan akurasi tertinggi mencapai 65%. Model tersebut dioptimalisasi oleh optimizer Adam. Namun, penelitian lebih lanjut masih diperlukan untuk meningkatkan akurasi dan keandalan model.

Penelitian selanjutnya akan berfokus pada pengembangan praprocessing pada dataset citra Ikan untuk mengatasi kondisi gambar ikan yang tidak sempurna dan memperluas penggunaannya pada objek lain selain ikan, serta mengeksplorasi model deep learning lain untuk meningkatkan performa identifikasi ikan multi-kelas.

#### DAFTAR PUSTAKA

- [1] A. N.S., S. D., and R. K. S., "Naive Bayesian fusion based deep learning networks for multisegmented classification of fishes in aquaculture industries," *Ecol Inform*, vol. 61, Mar. 2021, doi: 10.1016/j.ecoinf.2021.101248.
- [2] J. Soom, V. Pattanaik, M. Leier, and J. A. Tuhtan, "Environmentally adaptive fish or no-fish classification for river video fish counters using high-performance desktop and embedded hardware," *Ecol Inform*, vol. 72, Dec. 2022, doi: 10.1016/j.ecoinf.2022.101817.
- [3] E. Prasetyo, N. Suciati, and C. Fatichah, "Multi-level residual network VGGNet for fish species classification," *Journal of King Saud University - Computer and Information Sciences*, vol. 34, no. 8, pp. 5286–5295, Sep. 2022, doi: 10.1016/j.jksuci.2021.05.015.
- [4] A. Banerjee *et al.*, "Carp-DCAE: Deep convolutional autoencoder for carp fish classification," *Comput Electron Agric*, vol. v. 196, pp. 106810--2022 v.196, 2022, doi: 10.1016/j.compag.2022.106810.
- [5] V. Kandimalla, M. Richard, F. Smith, J. Quirion, L. Torgo, and C. Whidden, "Automated Detection, Classification and Counting of Fish in Fish Passages With Deep Learning," *Front Mar Sci*, vol. 8, Jan. 2022, doi: 10.3389/fmars.2021.823173.
- [6] S. Z. H. Shah *et al.*, "Fish-Pak: Fish species dataset from Pakistan for visual features based classification," *Data Brief*, vol. 27, Dec. 2019, doi: 10.1016/j.dib.2019.104565.

- [7] N. H. Shabrina, R. A. Lika, and S. Indarti, "Deep learning models for automatic identification of plant-parasitic nematode," *Artificial Intelligence in Agriculture*, vol. 7, pp. 1–12, Mar. 2023, doi: 10.1016/j.aiia.2022.12.002.
- [8] M. De Graeve, N. Birse, Y. Hong, C. T. Elliott, L. Y. Hemeryck, and L. Vanhaecke, "Multivariate versus machine learning-based classification of rapid evaporative Ionisation mass spectrometry spectra towards industry based large-scale fish speciation," *Food Chem*, vol. 404, Mar. 2023, doi: 10.1016/j.foodchem.2022.134632.
- [9] L. Boussaad and A. Boucetta, "An effective component-based age-invariant face recognition using Discriminant Correlation Analysis," *Journal of King Saud University - Computer and Information Sciences*, vol. 34, no. 5, pp. 1739–1747, May 2022, doi: 10.1016/j.jksuci.2020.08.009.
- [10] V. Kandimalla, M. Richard, F. Smith, J. Quirion, L. Torgo, and C. Whidden, "Automated Detection, Classification and Counting of Fish in Fish Passages With Deep Learning," *Front Mar Sci*, vol. 8, Jan. 2022, doi: 10.3389/fmars.2021.823173.
- [11] Paper Whitecode, "Image Classification on ImageNet," <https://paperswithcode.com/sota/image-classification-on-imagenet>, Apr. 06, 2023.
- [12] M. Yang, X. Huang, L. Huang, and G. Cai, "Diagnosis of Parkinson's disease based on 3D ResNet: The frontal lobe is crucial," *Biomed Signal Process Control*, vol. 85, p. 104904, Aug. 2023, doi: 10.1016/j.bspc.2023.104904.
- [13] B. Falahkhi, E. F. Achmal, M. Rizaldi, R. Rizki, and N. Yudistira, "Perbandingan Model AlexNet dan ResNet dalam Klasifikasi Citra Bunga Memanfaatkan Transfer Learning Comparison of AlexNet and ResNet Models in Flower Image Classification Utilizing Transfer Learning", [Online]. Available: <http://journal.ipb.ac.id/index.php/jika>
- [14] Z. Dai, H. Liu, Q. V Le, and M. Tan, "CoAtNet: Marrying Convolution and Attention for All Data Sizes."
- [15] M. Tan and V. Q. Le, "EfficientNetV2: Smaller Models and Faster Training," Jun. 2021.
- [16] M. Toğaçar, B. Ergen, and Z. Cömert, "Tumor type detection in brain MR images of the deep model developed using hypercolumn technique, attention modules, and residual blocks," *Med Biol Eng Comput*, vol. 59, no. 1, pp. 57–70, Jan. 2021, doi: 10.1007/s11517-020-02290-x.