

Penentuan Metode Augmentasi pada CNN Berdasarkan Metode Optimasi Fox untuk Klasifikasi Citra Ikan

Firman Wahyudi¹, Siti Hadiati Nugraini², Moch. Arief Soeleman³,
Ricardus Anggi Pramunendar^{4*}, Pulung Nurtantio Andono⁵

^{1,3,4,5} Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Dian Nuswantoro

² Program Studi Desain Komunikasi Visual, Fakultas Ilmu Komputer,
Universitas Dian Nuswantoro,

*Email: ricardus.anggi@dsn.dinus.ac.id

Abstrak

Identifikasi spesies ikan secara otomatis memiliki peran penting dalam berbagai bidang seperti biologi konservasi, manajemen perikanan, dan penelitian biologi. Metode Convolutional Neural Network (CNN) telah menjadi solusi efektif untuk mengotomatisasi proses ini dari gambar digital. Namun, untuk mencapai akurasi tinggi diperlukan pertimbangan yang teliti terhadap faktor-faktor seperti jumlah dan kualitas data, metode pengolahan gambar, teknik ekstraksi fitur, algoritma klasifikasi, dan metode optimasi. Penelitian ini mengatasi tantangan ini dengan mengusulkan model CNN yang dioptimalkan menggunakan algoritma FOX untuk memilih metode augmentasi yang terbaik. Hasil penelitian menunjukkan bahwa pemilihan teknik augmentasi yang tepat, seperti Kmeans Color Quantization, Horizontal Flip, Voronoi, Elastic Transformation, dan Contrast Normalization, dapat secara signifikan meningkatkan akurasi pengenalan spesies ikan hingga 98,75% pada tahap pelatihan. Model usulan ini juga menunjukkan kemampuan generalisasi yang kuat dengan akurasi validasi mencapai 96,90%, menunjukkan bahwa model ini minim mengalami overfitting. Meskipun memerlukan waktu pelatihan yang intensif, pendekatan ini terbukti sangat efektif untuk aplikasi yang membutuhkan akurasi tinggi dan kemampuan umum yang baik, sehingga dapat meningkatkan pemahaman dan pengelolaan ekosistem laut dalam mendukung praktik perikanan yang berkelanjutan.

Kata kunci: klasifikasi citra ikan, convolutional neural network, augmentasi, seleksi fitur, fox optimization algorithm

Abstract

Automatic identification of fish species plays an important role in various fields such as conservation biology, fisheries management, and biological research. The Convolutional Neural Network (CNN) method has become an effective solution for automating this process using digital images. However, achieving high accuracy requires careful consideration of factors such as the quantity and quality of data, image preprocessing methods, feature extraction techniques, classification algorithms, and optimization strategies. This study addresses these challenges by proposing a CNN model optimized using the FOX optimization algorithm to select the most suitable augmentation methods. The results show that selecting appropriate augmentation techniques, such as K-means Color Quantization, Horizontal Flip, Voronoi, Elastic Transformation, and Contrast Normalization, can significantly improve the accuracy of fish species recognition, reaching up to 98.75 percent during the training phase. The proposed model also demonstrates strong generalization capabilities with a validation accuracy of 96.90 percent, indicating minimal overfitting. Although the training process is computationally intensive, this approach has proven to be highly effective for applications that require high accuracy and strong generalization capabilities, thus contributing to a better understanding and management of marine ecosystems in support of sustainable fisheries practices..

Keywords: fish image classification, convolutional neural network, augmentation, feature selection, FOX optimization algorithm.

PENDAHULUAN

Pengembangan teknik identifikasi spesies, termasuk identifikasi ikan, memiliki peran penting dalam berbagai bidang seperti konservasi alam, manajemen perikanan, dan penelitian biologi. Pengenalan spesies ikan dengan akurat merupakan langkah awal yang krusial dalam upaya memahami ekosistem laut serta menjaga keberlanjutan sumber daya perikanan. Dengan kemajuan teknologi, pendekatan komputasional, terutama Convolutional Neural Network (CNN), telah terbukti sebagai solusi efektif untuk mengotomatisasi proses identifikasi spesies ikan dari citra digital (Siddiqui et al., 2018).

Otomatisasi pengenalan jenis ikan menggunakan teknik kecerdasan buatan telah dilakukan dalam beberapa peneliti dan sebagian besar menggunakan metode CNN. Namun, variasi hasil pengenalan jenis ikan antara penelitian menunjukkan bahwa kinerja sistem sangat bergantung pada faktor-faktor seperti kuantitas dan kualitas data, metode pengolahan citra (Tian et al., 2020), fitur (Liang et al., 2020; Ma and Gao, 2020a; Ma and Teng, 2019; Mahanipour et al., 2018; Mahanipour and Nezamabadi-pour, 2019; Peng et al., 2021; Tran et al., 2019), teknik klasifikasi yang digunakan, serta metode optimasi untuk mencapai kinerja terbaik (Liang et al., 2020; Ma and Gao, 2020b; Mahanipour et al., 2018; Tran et al., 2019). Meskipun banyak penelitian menggunakan data lingkungan bawah air, sedikit yang mempertimbangkan efek lingkungan tersebut dalam pengembangan metode (Sayed et al., 2018).

Dari berbagai penelitian hanya sedikit yang memanfaatkan data dipengaruhi kondisi lingkungan bawah air. Salman dkk (Salman et al., 2016) mengusulkan metode berbasis CNN dan metode klasifikasi SVM. Metode ini digunakan untuk mengenali 10 jenis ikan yang terdiri dari 19.868 citra dari data fish4knowledge, dengan kinerja akurasi sebesar 93,65%. Penelitian menggunakan metode dan sumber data yang sama dari Salman dkk (Salman et al., 2016) dilakukan oleh Qin dkk (Qin et al., 2016) yang mampu memperoleh kinerja akurasi sebesar 98,13% dengan menggunakan 11.724 citra ikan dari 23 jenis ikan. Selain Salman dkk (Salman et al., 2016) dan Qin dkk (Qin et al., 2016) metode yang sama diterapkan oleh Siddiqui dkk (Siddiqui et al., 2018). Perbedaan penelitian Siddiqui dkk (Siddiqui et al., 2018)

adalah penerapan metode detektor fitur umum sebelum menerapkan metode CNN, serta penggunaan data yang tidak berasal dari fish4knowledge tetapi dipengaruhi oleh kondisi bawah air. Berbeda dengan penelitian Salman dkk (Salman et al., 2016) dan Hsiao dkk (Hsiao et al., 2014), penelitian Siddiqui dkk (Siddiqui et al., 2018) melakukan perbandingan terhadap hasil kinerja penelitian sebelumnya, dengan kinerja akurasi sebesar 94,3%, lebih tinggi daripada Salman dkk (Salman et al., 2016) dan Hsiao dkk (Hsiao et al., 2014).

Beberapa isu utama yang banyak dibahas dalam penerapan pengenalan jenis ikan diantaranya adalah heterogenitas data pelatihan dan target, serta pengaruh lingkungan bawah air pada data tersebut (Hsiao et al., 2014; Qin et al., 2016; Salman et al., 2016; Siddiqui et al., 2018). Penggunaan data fish4knowledge yang beragam jumlahnya menjadi perhatian pada beberapa penelitian, sementara metode yang digunakan cenderung tidak mempertimbangkan dampak lingkungan bawah air. Umumnya, metode yang diterapkan melibatkan pengolahan fitur ekstraksi yang diterapkan pada berbagai metode klasifikasi untuk pengenalan jenis ikan. Peningkatan kualitas citra dan proses pengolahan fitur menjadi krusial dalam meningkatkan akurasi pengenalan jenis ikan. Oleh karena itu, kedua tahap tersebut dianggap penting untuk mencapai tingkat akurasi yang tinggi dalam pengenalan jenis ikan.

Penelitian ini berkontribusi pada salah satu hal penting yaitu pentingnya kualitas citra untuk peningkatan akurasi identifikasi ikan. Adapun metode yang digunakan adalah metode CNN yang berbasis optimasi metode augmentasi berdasarkan optimasi FOX. Pemilihan metode augmentasi yang tepat dilakukan dengan mempertimbangkan pentingnya pengaruh kondisi lingkungan bawah air. Dengan demikian, penelitian ini menghasilkan model yang lebih robust dan aplikatif pada data nyata, meningkatkan pemahaman tentang ekosistem laut. Implikasinya mencakup berbagai bidang seperti pemantauan lingkungan, konservasi sumber daya perikanan, dan pengelolaan perikanan berkelanjutan, mendukung konsep ekonomi biru yang menekankan pada keseimbangan antara pemanfaatan dan pelestarian sumber daya laut.

PENELITIAN TERKAIT

Dari berbagai penelitian (Boom et al., 2014; Hsiao et al., 2014; Huang, 2016; Lee et al., 2016; Salman et al., 2016; Sayed et al., 2018; Spampinato et al., 2016, 2014), terdapat sedikit penelitian yang memanfaatkan data dengan dipengaruhi kondisi lingkungan bawah air seperti Spampinato dkk (Spampinato et al., 2016, 2014), Hsiao dkk (Hsiao et al., 2014), Boom dkk (Boom et al., 2014), Huang dkk (Huang, 2016), Salman dkk (Salman et al., 2016), Qin dkk (Qin et al., 2016) dan Siddiqui dkk (Siddiqui et al., 2018). Penelitian Spampinato dkk (Spampinato et al., 2014) menggunakan kecerdasan buatan untuk mengenali 13 jenis ikan dari 3.179 citra fish4knowledge. Fitur bentuk diambil dengan metode invariant moment, sementara fitur tekstur menggunakan HOG, GLCM, Gabor filter, dan Fourier descriptor. Kombinasi fitur ini diklasifikasi dengan SVM, menghasilkan akurasi 86,32%. Penelitian Boom dkk (Boom et al., 2014) menggunakan fitur dan data serupa dengan Spampinato dkk (Spampinato et al., 2014), namun mengusulkan klasifikasi BGOT berbasis SVM untuk mengatasi ketidakseimbangan data. Mereka mencapai kinerja 97,21%, lebih tinggi dari Spampinato dkk (Spampinato et al., 2014). Hasil penelitian Boom dkk (Boom et al., 2014) dilanjutkan oleh Huang dkk (Huang, 2016) dengan menambahkan gaussian mixture model (GMM). Penelitian Huang dkk (Huang, 2016) diujikan pada data fish4knowledge dengan jumlah citra sebanyak 24.150 citra ikan dari 15 jenis ikan dan menghasilkan kinerja akurasi sebesar 95%.

Hsiao dkk (Hsiao et al., 2014) menggunakan data fish4knowledge dan modifikasi eigenface serta fisherfaces, diikuti oleh klasifikasi sparse representation-based, mencapai akurasi 81,8% pada 1.000 citra ikan dari 25 jenis. Namun penelitian (Hsiao et al., 2014) tidak dibandingkan dengan beberapa metode klasifikasi penelitian sebelumnya. Spampinato dkk (Spampinato et al., 2016) memberikan usulan lain menggunakan metode ekstraksi fitur SIFT dan LTP, dengan klasifikasi SVM, pada data fish4knowledge. Data terdiri dari 24.441 citra pelatihan dan 6.956 citra pengujian, menghasilkan presisi 91%.

Salman dkk (Salman et al., 2016) menggunakan CNN dan SVM untuk mengenali 10 jenis ikan dari 19.868 citra fish4knowledge, dengan akurasi 93,65%. Qin dkk (Qin et al., 2016)

menggunakan metode dan data yang sama, mencapai akurasi 98,13% dari 11.724 citra ikan. Siddiqui dkk (Siddiqui et al., 2018) menerapkan generalized feature detector sebelum CNN pada data bawah air, menghasilkan akurasi 94,3%, lebih tinggi dibanding Salman dkk (Salman et al., 2016) dan Hsiao dkk (Hsiao et al., 2014).


Isu utama dalam pengenalan jenis ikan mencakup heterogenitas data dan pengaruh lingkungan bawah air. Metode yang umum digunakan melibatkan ekstraksi fitur dan klasifikasi, tetapi sering tidak mempertimbangkan dampak lingkungan bawah air. Peningkatan kualitas citra dan proses ekstraksi fitur krusial untuk meningkatkan akurasi pengenalan jenis ikan karena keduanya memiliki keterkaitan. Oleh karena itu, fokus utama pada penelitian ini adalah di peningkatan kualitas citra melalui pemilihan metode augmentasi terbaik.

METODE PENELITIAN

Penelitian ini mengusulkan pendekatan baru untuk identifikasi jenis ikan menggunakan Convolutional Neural Network (CNN) yang dioptimalkan oleh algoritma optimasi FOX untuk pemilihan metode augmentasi terbaik. Berbeda dengan penelitian sebelumnya yang hanya fokus pada pengolahan citra khusus, pendekatan ini mengintegrasikan CNN dengan metode optimasi swarm-based. Selain memanfaatkan teknologi AI canggih, penelitian ini juga menggunakan kekuatan algoritma optimasi untuk meningkatkan performa pengenalan ikan. Adapun alur penelitian ini diperlihatkan pada Gambar 1.

3.1. Review Literatur

Review literatur mengenai metode pengenalan ikan bertujuan untuk memahami perkembangan terbaru dan mengidentifikasi celah penelitian yang belum terpenuhi. Kata kunci pencarian artikel untuk literatur yang digunakan adalah *fish recognition*, *fish classification*, hingga *augmentation selection*. Melalui review ini, peneliti dapat mengeksplorasi teknik-teknik yang telah diterapkan, hasil yang telah dicapai, serta masalah-masalah umum yang dihadapi dalam bidang ini. Hal ini juga membantu dalam mengenali tren penelitian dan area yang memerlukan inovasi lebih lanjut.



Gambar 1. Usulan Penelitian

3.2. Identifikasi Masalah

Dalam mengenali masalah utama dalam pengenalan ikan, fokusnya pada heterogenitas data citra ikan yang dapat mempengaruhi akurasi pengenalan, pengaruh lingkungan bawah air seperti pencahayaan dan kekeruhan, serta keterbatasan dalam teknik pengolahan citra untuk menangani kompleksitas dan variasi data di bawah air.


3.3. Pengumpulan Data

Mengumpulkan data citra ikan dari sumber dataset publik yaitu fish4knowledge yang diperlihatkan seperti Tabel 1 dan Tabel 2. Data citra ikan ini mencakup 27.370 citra terverifikasi dari video langsung, dibagi menjadi 23 label citra (Boom et al., 2012). Citra menunjukkan perbedaan komponen, jumlah, dan bentuk sirip. Dataset ini sangat tidak seimbang, dengan spesies terbanyak terdeteksi sekitar 1000 kali lebih sering daripada yang paling sedikit (Pramunendar et al., 2020). Seperti yang diperlihatkan pada Gambar 2 tentang data fish4knowledge, dan Tabel 1 tentang dataset fish4knowledge

3.4. Metode Pendekatan

Mengembangkan pendekatan yang mengintegrasikan Convolutional Neural Network (CNN) dengan algoritma Fox Optimization untuk memilih metode augmentasi terbaik. Dalam penelitian ini, CNN digunakan untuk mengevaluasi hasil dari fungsi fitness

dalam algoritma FOX. Evaluasi terbaik didasarkan pada nilai akurasi.



Gambar 2. Data Fish4knowledge

3.4.1. Augmentasi

Penelitian ini menggunakan 60 metode augmentasi dari paket Python "imgaug" yang meliputi flipping horizontal, cropping acak, dan augmentasi ruang warna (Jung et al., 2020). Hanya subset tertentu dari berbagai proses pemrosesan gambar perpustakaan digunakan dalam penelitian ini. Metode augmentasi terbaik dipilih dari Tabel 2 dengan menggunakan Optimasi FOX, memilih lima kombinasi terbaik dari semua yang tersedia.

Tabel 1. Dataset Fish4Knowledge

ID	Species	Jumlah Data
1	<i>Dascyllus reticulatus</i>	12112
2	<i>Plectroglyphidodon dickii</i>	2683
3	<i>Chromis chrysura</i>	3593
4	<i>Amphiprion clarkii</i>	4049
5	<i>Chaetodon lunulatus</i>	2534
6	<i>Chaetodon trifascialis</i>	190
7	<i>Myripristis kuntze</i>	450
8	<i>Acanthurus nigrofasciatus</i>	218
9	<i>Hemigymnus fasciatus</i>	241
10	<i>Neoniphon sammara</i>	299
11	<i>Abudefduf vaigiensis</i>	98
12	<i>Canthigaster valentini</i>	147
13	<i>Pomacentrus moluccensis</i>	181
14	<i>Zebrafish</i>	90
15	<i>Hemigymnus melapterus</i>	42
16	<i>Lutjanus fulvus</i>	206
17	<i>Scolopsis bilineata</i>	49
18	<i>Scaridae</i>	56
19	<i>Pempheris vanicolensis</i>	29
20	<i>Zanclus cornutus</i>	21
21	<i>Neoglyphidodon nigroris</i>	16
22	<i>Balistapus undulatus</i>	41
23	<i>Siganus fuscescens</i>	25

* Sumber: Fish4Knowledge (Boom et al., 2012)

Tabel 2. List Metode Augmentasi

No	Metode	No	Metode
1	Affine (Rotasi, Skala, Translasi)	31	Speckle Noise
2	Horizontal Flip	32	Glass Blur
3	Vertical Flip	33	Defocus Blur
4	Contrast Normalization	34	Zoom Blur
5	Elastic Transformation	35	Fog
6	Kmeans Color Quantization	36	Frost
7	Superpixels	37	Snow
8	Voronoi	38	Spatter
9	Uniform Voronoi	39	Contrast
10	Regular Grid Voronoi	40	Brightness
11	Relative Regular Grid Voronoi	41	Saturate
12	Gaussian Blur	42	Pixelate
13	Average Blur	43	Elastic Transform
14	Median Blur	44	Solarize
15	Motion Blur	45	Equalize
16	Mean Shift Blur	46	Auto contrast
17	Gamma Contrast	47	Enhance Color
18	Sigmoid Contrast	48	Enhance Contrast
19	Log Contrast	49	Enhance Brightness
20	Linear Contrast	50	Enhance Sharpness
21	All Channels Clahe	51	Filter Blur
22	Clahe	52	Filter Smooth
23	Histogram Equalization	53	Filter Smooth More
24	Sharpen	54	Filter Edge Enhance
25	Emboss	55	Filter Edge Enhance More
26	Edge Detect	56	Filter Find Edges
27	Directed Edge Detect	57	Filter Contour
28	Gaussian Noise	58	Filter Emboss
29	Shot Noise	59	Filter Sharpen
30	Impulse Noise	60	Filter Detail

1) Exploitasi

Pada fase eksploitasi, jika variabel acak p lebih dari 0.18, rubah mencari posisi baru untuk menangkap mangsa. Untuk itu, dihitung jarak tempuh suara $DistST_{it}$ jarak rubah dan mangsa $DistFoxPrey_{it}$, dan nilai lompatan $Jump$. Waktu tempuh suara $TimeST_{it}$ ditentukan secara acak dalam rentang 0-1. Jarak suara dari rubah dihitung dengan kecepatan suara udara ($SpS = 343$ m/s) dikalikan dengan $TimeST_{it}$ (Mohammed and Rashid, 2023), sesuai persamaan (1). Jumlah iterasi berkisar 1-500. Persamaan lain menghitung SpS berdasarkan

3.4.2. Algoritma Optimasi FOX

Algoritma FOX dimulai dengan inisialisasi populasi X yang merepresentasikan posisi rubah. Fitness setiap agen dihitung menggunakan fungsi benchmark. BestFitness dan BestX ditentukan berdasarkan perbandingan fitness antar agen selama iterasi. Untuk mencapai keseimbangan antara eksplorasi dan eksploitasi, digunakan variabel acak untuk membagi iterasi antara kedua fase dalam algoritma FOX. Variabel memberikan probabilitas 50% untuk eksplorasi atau eksploitasi. Hal ini untuk menghindari jatuh ke dalam optimum lokal. Variabel a digunakan untuk meningkatkan kinerja pencarian berdasarkan BestX dengan mengurangi nilainya setiap iterasi. Dalam memperbarui posisi dipengaruhi oleh fungsi fitness, yang membantu agen menghindari jatuh ke optimum lokal. Jika posisi baru tidak berubah, fase eksplorasi dinonaktifkan untuk memberikan kesempatan pada fase lain untuk aktif.

posisi terbaik $BestPosition_{it}$ dalam populasi pencarian sesuai persamaan (2).

$$DistST_{it} = SpS \times TimesST_{it} \quad (1)$$

$$SpS = \left(\frac{BestPosition_{it}}{TimeST_{it}} \right) \quad (2)$$

Untuk menemukan jarak suara digunakan persamaan (3). Sebagai hasilnya, jarak rubah dari mangsa, $DistFoxPrey_{it}$ dapat dihitung dengan $DistST_{it}$ (4). Untuk menghitung jarak antara sensor dan objek dalam fisika, jarak suara dibagi dua karena sensor berjarak setengah dari jarak yang ditempuh gelombang suara (Mohammed and Rashid, 2023). Sensor mengirim dan menerima sinyal gelombang suara, sehingga waktu tempuh suara dikalikan dengan 0.5 atau dibagi dua. Operasi ini sama karena setengah gelombang suara.

$$DistFoxPrey_{it} = DistST_{it} \times 0.5 \quad (3)$$

$$DistST_{it} = SpS \times TimeST_{it} \quad (4)$$

Setelah menemukan jarak antara rubah dan mangsa, rubah perlu menghitung tinggi lompatan $Jump_{it}$ (5) untuk mencari posisi baru agar dapat melompat menangkap mangsa.

$$Jump_{it} = 0.5 \times 9.81 \times t^2 \quad (5)$$

Percepatan gravitasi adalah 9.81, dan t adalah waktu rata-rata suara, dipangkatkan dua karena langkah lompatan. Waktu transisi tt dihitung dari $TimeST_{it}$. t adalah setengah dari tt dikalikan dengan 0.5. Gravitasi dan t dikalikan dengan 0.5 untuk $Jump$ dengan $DistFoxPrey_{it}$ dan c_1

Nilai 9.81 adalah percepatan gravitasi, dan t adalah waktu rata-rata yang ditempuh suara, dipangkatkan dua karena langkah naik dan turun dalam lompatan. Waktu transisi tt dihitung dengan membagi jumlah $TimeST_{it}$ dengan dimensi. Persamaan (8) menunjukkan perhitungan tt dan $MinT$. Waktu rata-rata t ditemukan dengan membagi tt dengan 2. Gravitasi dan waktu rata-rata dikalikan dengan 0.5 karena lompatan memerlukan dua waktu yang berbeda untuk naik dan turun. Nilai $Jump$ dikalikan dengan $DistFoxPrey_{it}$ dan c_1 . Variabel c_1 berada dalam rentang $[0, 0.18]$ saat rubah melompat ke arah timur laut.

$$X_{it+1} = DistFoxPrey_{it} \times Jump_{it} \times c_1 \quad (6)$$

Persamaan (6) dan (7) digunakan untuk menemukan lokasi baru rubah. Hanya satu yang dieksekusi dalam setiap iterasi berdasarkan kondisi p . Perbedaan utamanya terletak pada bagian kedua kondisi p dalam Persamaan (5). Jika kondisi $p > 0.18$, Persamaan (5) dikalikan dengan c_2 bukan q . Jika $p \leq 0.18$, posisi baru dihitung dengan Persamaan (7). Rentang c_2 adalah $[0.19, 1]$.

$$X_{it+1} = DistFoxPrey_{it} \times Jump_{it} \times c_2 \quad (7)$$

Nilai c_1 dan c_2 adalah 0.18 dan 0.82 masing-masing. Nilai-nilai ini digunakan dalam gerakan lompatan rubah, entah ke arah timur laut atau sebaliknya. Jika $p > 0.18$, rubah melompat ke arah timur laut. Dalam hal ini, $DistFoxPrey_{it}$ dan $Jump_{it}$ dikalikan dengan c_1 , meningkatkan peluang untuk mencapai posisi optimal global. Namun, jika $p \leq 0.18$, rubah melompat ke arah berlawanan dari timur laut. Dalam kasus ini, $DistFoxPrey_{it}$ dan $Jump_{it}$ dikalikan dengan c_2 , mengurangi peluang untuk mencapai mangsa ($\leq 18\%$).

2) Explorasi

Rubah melakukan pencarian acak berdasarkan posisi terbaik yang telah ditemukan. Dalam fase ini, rubah berjalan acak untuk menjelajahi area pencarian mangsa tanpa teknik loncatan. Variabel $MinT$ dan aaa digunakan untuk mengontrol perjalanan acak menuju posisi terbaik rubah. Persamaan (8) dan (9) menjelaskan perhitungan dari $MinT$ dan a , dengan $MinT$ dihitung sebagai nilai minimum dari tt .

$$tt = \frac{\sum (TimeST_{it}(i, :))}{dimension}, MinT = Min(tt) \quad (8)$$

Rata-rata dari $TimeST_{it}$ diambil berdasarkan dimensi masalah untuk mencari nilai minimum dari waktu rata-rata tt .

$$a = 2 \times \left(it - \left(\frac{1}{Max_{it}} \right) \right) \quad (9)$$

Max_{it} adalah iterasi maksimum. Perhitungan $MinT$ dan variabel a krusial untuk fase pencarian menuju solusi terbaik. Rubah

menggunakan $rand(1, dimension)$ untuk eksplorasi stokastik dalam pencarian mangsa. Variabel r digunakan untuk seimbangkan eksplorasi dan eksploitasi. Solusi terbaik $BestX$ berpengaruh besar terhadap strategi eksplorasi rubah. Persamaan (9) menunjukkan teknik eksplorasi rubah dalam pencarian posisi baru di dalam ruang pencarian $X(i,i)X(i, + i)X(i,i)$, dapat disesuaikan dengan algoritma yang ada atau digunakan untuk mengembangkan algoritma metaheuristik baru.

$$X_{it+1} = BestX_{it} \times rand(1, dimension) \quad (10) \\ \times MinT \times a$$

Persamaan dalam kedua fase tidak memerlukan modifikasi, kecuali penyesuaian untuk masalah spesifik saat rubah digunakan untuk menyelesaikan masalah ruang multidimensi. Detail lengkap tentang FOX dapat ditemukan dalam Algoritma 1.


FOX dimulai dengan inialisasi populasi rubah merah secara acak dan memilih posisi terbaik berdasarkan nilai kebugaran terbaik dalam populasi. Iterasi terdiri dari fase eksploitasi atau eksplorasi tergantung pada nilai acak r dan kondisi p . Kompleksitas waktu FOX per iterasi adalah $O(n^2)$, di mana nnn adalah ukuran populasi, dengan kompleksitas ruang yang sama untuk vektor dan matriks dalam Algoritma 1.

3.4.3. Convolution Neural Network as an Evaluation Method

Penelitian ini memilih pendekatan FOX untuk menentukan teknik augmentasi optimal, menggunakan CNN untuk menghitung nilai fungsi kebugaran berdasarkan akurasi. CNN, model matematis dengan desain parametrik, terdiri dari lapisan input, beberapa lapisan tersembunyi, dan lapisan output (Priya and Muruganantham, 2019; Sultana et al., 2018). Setiap lapisan tersembunyi terhubung dengan bobot yang dapat diatur dan secara bertahap merepresentasikan aspek input citra yang semakin kompleks (Hopkinson et al., 2020). Kerangka CNN tradisional mencakup lapisan konvolusi, pooling, dan lapisan yang sepenuhnya terhubung (Sultana et al., 2018), yang bersama-sama mengubah representasi input awal ke level yang lebih tinggi dan konseptual. Metode CNN ini ditunjukkan pada Gambar 3.

Algoritma 1. FOX


1. Initialize the red fox population $X_i (i = 1, 2, \dots, n)$
2. While $i < Max(it)$:
 - Inialisasi variabel: $DistST, SpS, TimeST, BestX, DistFoxPrey, Jump, MinT, a, BestFitness$
 - Hitung nilai fitness setiap agen pencarian.
 - Pilih $BestX$ dan $BestFitness$ di antara populasi rubah (X) pada setiap iterasi.
 - Jika $fitness_i > fitness_{i+1}$
 - $BestFitness = fitness_{i+1}$
 - $BestX = X(i, :)$
 - Jika $r \geq 0.5$
 - Jika $p \geq 0.18$
 - Inialisasi waktu secara acak.
 - Hitung DistanceSoundtravels (1).
 - Hitung SpS (2).
 - Hitung jarak dari rubah ke mangsa (3).
 - T_t merupakan rata-rata waktu
 - $T = \frac{T_t}{2}$
 - Hitung lompatan $jump$ (5).
 - Temukan X_{it+1} (6).
 - Jika $p < 0.18$
 - Inialisasi waktu secara acak.
 - Hitung DistanceSoundtravels (1).
 - Hitung SpS dari Persamaan (2).
 - Hitung jarak dari rubah ke mangsa (3).
 - T_t merupakan rata-rata waktu
 - $T = \frac{T_t}{2}$
 - Hitung lompatan $jump$ (5).
 - Temukan X_{it+1} (7).
 - Jika $r < 0.5$
 - Temukan $MinT$ (8)
 - Eksplorasi X_{it+1} (10)
 - Periksa dan perbaiki posisi jika melampaui batas.
 - Evaluasi agen pencarian berdasarkan nilai fitness mereka.
 - Perbarui $BestX$.
 - $it = it + 1$
3. Return $BestX$ dan $BestFitness$



Gambar 3. CNN Model as an Evaluation Method

CNN meningkatkan ciri input yang berguna dan mengurangi variasi tidak relevan. Dibandingkan jaringan saraf feedforward, CNN memiliki lebih sedikit koneksi dan parameter, sehingga lebih mudah dilatih. Namun, performa optimalnya mungkin sedikit lebih rendah.

Kapasitas CNN bisa disesuaikan dengan mengatur lebar dan kedalamannya.



Gambar 4. Model CNN

1) CNN model

Model CNN untuk klasifikasi ikan menerima citra RGB 128 x 128 piksel dengan tiga saluran warna. Terdiri dari beberapa lapisan Conv2D dan MaxPooling2D berurutan. Lapisan Conv2D pertama memiliki 32 filter (3, 3) dengan fungsi aktivasi ReLU, diikuti MaxPooling2D (2, 2). Proses ini diulang empat kali dengan filter berturut-turut 64, 128, 128, dan 256, disertai MaxPooling2D setelah setiap Conv2D. Output diubah menjadi struktur datar dengan lapisan flatten. Ada lapisan dense dengan 512 neuron menggunakan ReLU, dan lapisan Dense akhir dengan 23 neuron menggunakan softmax (Gambar 4). Struktur ini meningkatkan kemampuan model mengekstraksi fitur relevan untuk klasifikasi.

2) Fungsi ReLU

Fungsi aktivasi ReLU digunakan dalam jaringan saraf karena sederhana dan efisien, serta mengatasi masalah "vanishing gradient" yang ada pada fungsi lain seperti sigmoid atau tanh (Shidik et al., 2024). Namun, ReLU memiliki kekurangan seperti "dying neuron," di mana neuron selalu menghasilkan output nol, sehingga menghambat pembelajaran. Persamaan diperlihatkan pada (3).

$$f(x) = \max(0, x) \quad (9)$$

3.5. Evaluasi Kinerja

Kinerja algoritma klasifikasi dinilai melalui perhitungan akurasi. Akurasi merujuk pada pengkategorian yang tepat dan akurat dari semua data yang diperoleh (Pramunendar et al., 2023). Nilai akurasi dihitung menggunakan persamaan (10), di mana t adalah jumlah data sampel yang diidentifikasi dengan benar dan n adalah total data sampel.

$$accuracy = (t/n) \times 100 \quad (10)$$

3.6. Desain Penelitian

Penelitian ini mencakup tahap implementasi dan optimisasi model identifikasi ikan. Implementasi dilakukan sesuai panduan, menggunakan perangkat keras seperti CPU Intel Core i9, kartu grafis Nvidia GeForce RTX 3060 Ti, dan RAM 64GB. Optimisasi dilakukan untuk menguji hasil kinerja dari optimasi yang dipilih oleh metode augmentasi berdasarkan epoch, dalam meningkatkan akurasi dan efisiensi. Validasi model dilakukan untuk menguji hasil pemilihan metode augmentasi terbaik. Akurasi digunakan untuk pengukuran dari metode yang diusulkan.

HASIL DAN PEMBAHASAN

4.1. Hasil Penelitian

Dalam percobaan ini, dilakukan klasifikasi menggunakan Convolutional Neural Network (CNN) terhadap data citra ikan yang mencakup 23 spesies berbeda. Metode augmentasi digunakan untuk meningkatkan kualitas citra yang telah disegmentasi, sementara metode optimisasi FOX digunakan untuk memilih kombinasi terbaik dari berbagai metode augmentasi yang tersedia. Hasil eksperimen menunjukkan bahwa metode augmentasi seperti Kmeans Color Quantization, Horizontal Flip, Voronoi, Elastic Transformation, dan Contrast Normalization berhasil mencapai akurasi 98.75% pada data pelatihan. Di sisi lain, metode augmentasi seperti Frost, Elastic Transformation, FilterEdgeEnhance, ShotNoise, dan MotionBlur hanya memberikan akurasi sebesar 97.73% pada data yang sama. Perbedaan ini menyoroti pentingnya pemilihan metode augmentasi yang tepat dalam meningkatkan akurasi model yang dikembangkan. Hasil perbaikan masing masing augmentasi yang terpilih diperlihatkan pada Tabel 3 dan Tabel 4. Hasil tersebut digunakan sebagai kombinasi metode augmentasi pada klasifikasi CNN.

Selain ditampilkan hasil augmentasi untuk masing masing citra, hasil kinerja akurasi untuk pelatihan diperlihatkan pada Gambar 5. Pada Gambar 5 memperlihatkan hasil eksperimen yang menunjukkan bahwa model mencapai peningkatan akurasi yang konsisten selama proses iterasi. Setiap iterasi melibatkan sepuluh percobaan berbeda, dengan hasil terbaik terjadi pada iterasi kedelapan. Awalnya, akurasi dimulai dari 98.10% pada iterasi pertama, mengalami variasi kecil pada beberapa iterasi

awal seperti 98.28% pada iterasi kedua dan ketiga, serta sedikit penurunan menjadi 98.20% pada iterasi keempat. Meskipun terjadi penurunan ke 97.73% pada iterasi kelima, model berhasil pulih dan mencatatkan peningkatan signifikan pada iterasi selanjutnya, mencapai 98.75% pada iterasi kedelapan. Iterasi kesembilan dan kesepuluh menunjukkan tingkat akurasi yang stabil, yaitu 98.55% dan 98.56% secara berturut-turut. Analisis menunjukkan bahwa model cenderung stabil dengan tren peningkatan akurasi secara keseluruhan, meskipun terdapat fluktuasi kecil di beberapa titik iterasi.

Tabel 3. Augmentasi Terbaik yang terpilih


Kmeans Color Quantization	
Horizontal Flip	
Voronoi	
Elastic Transformation	
Contrast Normalization	

Hasil eksperimen pada Gambar 6 menunjukkan bahwa model mengalami variasi yang relatif stabil dalam tingkat akurasi validasi selama sepuluh iterasi yang dilakukan. Dimulai dengan 96.43% pada iterasi pertama, akurasi mengalami sedikit variasi pada iterasi awal, mencapai puncak tertinggi pada iterasi kedua dengan 97.06%. Selanjutnya, terlihat fluktuasi kecil dalam akurasi pada beberapa iterasi, seperti pada iterasi keempat yang mencatatkan 96.40%, dan pada iterasi keenam dengan 96.80%. Secara keseluruhan, meskipun terjadi fluktuasi kecil, model mempertahankan tingkat akurasi yang relatif stabil di sekitar kisaran 96.40% hingga 97.06% sepanjang eksperimen. Analisis dari data ini menunjukkan bahwa model cenderung


konsisten dalam performa dengan sedikit variasi, yang dapat dianggap sebagai indikasi stabilitas yang baik dalam hasil validasi pada setiap iterasi.

Tabel 4. Augmentasi Terendah yang terpilih

Frost	
Elastic Transformation	
Filter Edge Enhance	
Shot Noise	
Motion Blur	



Gambar 5. Hasil terbaik pelatihan tiap iterasi



Gambar 6. Hasil terbaik validasi tiap iterasi

Perbedaan antara akurasi pelatihan (Gambar 5) dan validasi (Gambar 6), meskipun tidak signifikan, mengindikasikan bahwa model dapat mengalami sedikit *overfitting* terhadap data pelatihan, terutama mengingat bahwa akurasi validasi cenderung stabil dan tidak jauh dari akurasi pelatihan. Namun Analisis Anova

menunjukkan perbedaan yang signifikan antara akurasi pelatihan dan akurasi validasi ($F = 267.504$, $p < 0.05$), menunjukkan model cenderung *overfitting* terhadap data pelatihan. Variabilitas antar iterasi tidak signifikan secara statistik ($F = 2.321$, $p > 0.05$), menunjukkan konsistensi dalam performa model di setiap iterasi.

4.2. Pembahasan

Berdasarkan hasil percobaan yang telah dilakukan, diperlihatkan bahwa metode optimasi FOX berhasil menunjukkan kemampuannya dalam mengkombinasikan berbagai metode augmentasi data dan menghasilkan kinerja akurasi yang optimal pada model CNN. Secara spesifik, metode ini mencapai akurasi tertinggi sebesar 98.75% pada tahap pelatihan. Hal ini menandakan bahwa model mampu belajar dengan sangat baik dari data latih yang tersedia. Selain itu, akurasi pada tahap validasi yang mencapai 96.90% menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik terhadap data baru yang tidak terlihat selama pelatihan. Waktu pelatihan yang dibutuhkan untuk mencapai hasil ini adalah 103413.83 detik, menunjukkan bahwa penggunaan metode FOX memerlukan komputasi yang cukup intensif. Meskipun demikian, hasil yang dicapai membuktikan bahwa waktu pelatihan yang panjang ini sebanding dengan performa akurasi yang diperoleh. Dengan demikian, perbedaan yang kecil antara hasil akurasi pada tahap pelatihan dan validasi mengindikasikan bahwa model ini tidak mengalami *overfitting* yang signifikan, sebuah kondisi yang sering dihindari dalam pelatihan model machine learning. Keberhasilan metode FOX dalam mencapai kinerja yang ideal, dimana akurasi pelatihan dan validasi memiliki selisih yang minimal, menjadikannya sebagai pendekatan yang sangat efektif dalam konteks pengembangan model CNN. Oleh karena itu, meskipun memerlukan waktu pelatihan yang lama, metode ini sangat direkomendasikan untuk aplikasi yang membutuhkan tingkat akurasi yang tinggi dan generalisasi yang baik. Hal ini semakin menegaskan bahwa metode optimasi FOX tidak hanya unggul dalam memadukan teknik augmentasi, tetapi juga dalam menghasilkan model yang mampu memberikan performa akurasi yang konsisten dan handal.

SIMPULAN

Pengembangan teknik identifikasi spesies ikan melalui pendekatan komputasional, seperti Convolutional Neural Network (CNN), memberikan solusi yang efektif karena mampu mengotomatisasi proses identifikasi dari citra digital. Hasil penelitian ini menunjukkan bahwa penggunaan algoritma optimasi FOX dapat membantu dalam menentukan teknik augmentasi terbaik, seperti K-means Color Quantization, Horizontal Flip, Voronoi, Elastic Transformation, dan Contrast Normalization, sehingga akurasi pengenalan spesies ikan meningkat hingga 98,75% pada tahap pelatihan. Sebaliknya, teknik augmentasi lain hanya menghasilkan akurasi sebesar 97,73%, yang mengindikasikan bahwa pemilihan teknik augmentasi memiliki pengaruh signifikan terhadap kinerja model.

Model CNN yang dioptimalkan menggunakan FOX juga menunjukkan konsistensi performa, dengan akurasi pelatihan sebesar 98,75% dan akurasi validasi sebesar 96,90%, sehingga penurunan kinerja antara tahap pelatihan dan validasi dapat diminimalkan. Meskipun proses pelatihan memerlukan waktu yang cukup intensif, pendekatan ini terbukti efektif karena mampu menghasilkan tingkat akurasi yang tinggi dan generalisasi yang baik. Oleh karena itu, model ini memiliki potensi besar untuk diterapkan dalam bidang konservasi lingkungan, manajemen perikanan, dan penelitian biologi guna mendukung pengelolaan sumber daya laut secara berkelanjutan.

Untuk pengembangan lebih lanjut, penelitian ini dapat diarahkan pada penerapan model dalam kondisi nyata di lapangan. Hal ini penting karena variabilitas lingkungan pada data dunia nyata memerlukan adaptasi model yang lebih kuat. Selain itu, integrasi dengan sistem identifikasi waktu nyata dan eksplorasi algoritma optimasi yang lebih efisien juga perlu dilakukan agar waktu pelatihan dapat dikurangi tanpa mengurangi akurasi model.

UCAPAN TERIMA KASIH

Penelitian ini didukung dan didanai oleh Kementerian Riset dan Pendidikan Tinggi Indonesia (DPRM-DIKTI) dan Universitas Dian Nuswantoro, khususnya melalui Pusat Penelitian untuk Pengawasan dan Keamanan Terdistribusi yang Cerdas, dengan penekanan khusus pada

Studi Kecerdasan Buatan dalam Konservasi Alam dan Bencana Alam.

DAFTAR PUSTAKA

- Boom, B.J., He, J., Palazzo, S., Huang, P.X., Beyan, C., Chou, H.M., Lin, F.P., Spampinato, C., Fisher, R.B., 2014. A research tool for long-term and continuous analysis of fish assemblage in coral-reefs using underwater camera footage. *Ecological Informatics* 23, 83–97.
- Boom, B.J., Huang, P.X., He, J., Fisher, R.B., 2012. Supporting ground-truth annotation of image datasets using clustering. *Proceedings - International Conference on Pattern Recognition* 1542–1545.
- Hopkinson, B.M., King, A.C., Owen, D.P., Johnson-Roberson, M., Long, M.H., Bhandarkar, S.M., 2020. Automated classification of three-dimensional reconstructions of coral reefs using convolutional neural networks. *PLoS ONE* 15, 1–20.
- Hsiao, Y.H., Chen, C.C., Lin, S.I., Lin, F.P., 2014. Real-world underwater fish recognition and identification, using sparse representation. *Ecological Informatics* 23, 13–21.
- Huang, P.X., 2016. Hierarchical Classification System with Reject Option for Live Fish Recognition. In: *Machine Vision and Applications*. pp. 141–159.
- Jung, A.B., Wada, K., Crall, J., Tanaka, S., Graving, J., Reinders, C., Yadav, S., Banerjee, J., Vecsei, G., Kraft, A., Rui, Z., Borovec, J., Vallentin, C., Zhydenko, S., Pfeiffer, K., Cook, B., Fernández, I., De Rainville, F.-M., Weng, C.-H., Ayala-Acevedo, A., Meudec, R., Laporte, M., Others, 2020. *imgaug* [WWW Document]. <https://github.com/aleju/imgaug>. URL <https://github.com/aleju/imgaug>
- Lee, S., Yun, S., Nam, J.H., Won, C.S., Jung, S.W., 2016. A review on dark channel prior based image dehazing algorithms. *Eurasip Journal on Image and Video Processing* 2016, 1–23.
- Liang, J., Xue, Y., Wang, J., 2020. Genetic programming based feature construction methods for foreground object segmentation. *Engineering Applications of Artificial Intelligence* 89, 103334.
- Ma, J., Gao, X., 2020a. Designing genetic programming classifiers with feature selection and feature construction. *Applied Soft Computing Journal* 97, 106826.
- Ma, J., Gao, X., 2020b. A filter-based feature construction and feature selection approach for classification using Genetic Programming. *Knowledge-Based Systems* 196, 105806.
- Ma, J., Teng, G., 2019. A hybrid multiple feature construction approach for classification using Genetic Programming. *Applied Soft Computing Journal* 80, 687–699.
- Mahanipour, A., Nezamabadi-pour, H., 2019. A multiple feature construction method based on gravitational search algorithm. *Expert Systems with Applications* 127, 199–209.
- Mahanipour, A., Nezamabadi-Pour, H., Nikpour, B., 2018. Using fuzzy-rough set feature selection for feature construction based on genetic programming. *3rd Conference on Swarm Intelligence and Evolutionary Computation, CSIEC 2018* 1–6.
- Mohammed, H., Rashid, T., 2023. FOX: a FOX-inspired optimization algorithm. *Applied Intelligence* 53, 1030–1050.
- Peng, B., Wan, S., Bi, Y., Xue, B., Zhang, M., 2021. Automatic Feature Extraction and Construction Using Genetic Programming for Rotating Machinery Fault Diagnosis. *IEEE Transactions on Cybernetics* 51, 4909–4923.
- Pramunendar, R.A., Andono, P.N., Shidik, G.F., Megantara, R.A., Pergiawati, D., Prabowo, D.P., Sari, Y., Soong, L.W., 2023. Integrating Grey Wolf Optimizer for Feature Selection in Birdsong Classification Using K-Nearest Neighbours Algorithm. *International Journal of Intelligent Engineering and Systems* 16, 695–705.
- Pramunendar, R.A., Prabowo, D.P., Pergiawati, D., Sari, Y., Andono, P.N., Soeleman, M.A., 2020. New workflow for marine fish classification based on combination features and CLAHE enhancement technique. *International Journal of Intelligent Engineering and Systems* 13, 293–304.
- Priya, C.P., Muruganantham, S., 2019. Coral reef image classifications with hybrid methods. *International Journal of Innovative Technology and Exploring Engineering* 8, 1247–1254.
- Qin, H., Li, X., Liang, J., Peng, Y., Zhang, C.,

2016. DeepFish: Accurate underwater live fish recognition with a deep architecture. *Neurocomputing* 187, 49–58.
- Salman, A., Jalal, A., Shafait, F., Mian, A., Shortis, M., Seager, J., Harvey, E., 2016. Fish species classification in unconstrained underwater environments based on deep learning. *Limnology and Oceanography: Methods* 14, 570–585.
- Sayed, G.I., Hassanien, A.E., Gamal, A., Ella, H.A., 2018. An Automated Fish Species Identification System Based on Crow Search Algorithm. *Advances in Intelligent Systems and Computing* 723, 112–123.
- Shidik, G.F., Pramunendar, R.A., Kusuma, E.J., Saraswati, G.W., Winarsih, N.A.S., Rohman, M.S., Saputra, F.O., Naufal, M., Andono, P.N., 2024. LUTanh Activation Function to Optimize BI-LSTM in Earthquake Forecasting. *International Journal of Intelligent Engineering and Systems* 17, 572–583.
- Siddiqui, S.A., Salman, A., Malik, M.I., Shafait, F., Mian, A., Shortis, M.R., Harvey, E.S., 2018. Automatic fish species classification in underwater videos: Exploiting pre-trained deep neural network models to compensate for limited labelled data. *ICES Journal of Marine Science* 75, 374–389.
- Spampinato, C., Beauxis-Aussalet, E., Palazzo, S., Beyan, C., Van Ossenbruggen, J., He, J., Boom, B., Huang, X., 2014. A rule-based event detection system for real-life underwater domain. *Machine Vision and Applications* 25, 99–117.
- Spampinato, C., Palazzo, S., Joalland, P.H., Paris, S., Glotin, H., Blanc, K., Lingrand, D., Precioso, F., 2016. Fine-grained object recognition in underwater visual data. *Multimedia Tools and Applications* 75, 1701–1720.
- Sultana, F., Sufian, A., Dutta, P., 2018. Advancements in image classification using convolutional neural network. *Proceedings - 2018 4th IEEE International Conference on Research in Computational Intelligence and Communication Networks, ICRICIN 2018* 122–129.
- Tian, H., Wang, T., Liu, Y., Qiao, X., Li, Y., 2020. Computer vision technology in agricultural automation —A review. *Information Processing in Agriculture* 7, 1–19.
- Tran, B., Xue, B., Zhang, M., 2019. Genetic programming for multiple-feature construction on high-dimensional classification. *Pattern Recognition* 93, 404–417.