

Optimalisasi Algoritma *Deep Learning* Menggunakan Deteksi Tepi Pada Identifikasi Varietas Ikan Nila

Saeful Bahri^{1*}, Miftah Farid Adiwisastra², Recha Abriana Anggraini³, Herlan Sutisna⁴

¹Ilmu Komputer, Universitas Bina Sarana Informatika Kampus Kota Sukabumi, Sukabumi, Indonesia

^{2,3,4}Sistem Informasi, Universitas Bina Sarana Informatika Kampus Kota Tasikmalaya, Tasikmalaya, Indonesia

*email Corresponding author: saeful.sel@bsi.ac.id

Abstract

Tilapia is a fish species that is considered invasive throughout the world, but has high economic value in Indonesia because of its environmental resistance and popularity. There are 12 superior varieties of tilapia that want to be identified in this research. Because the shape of the fish's body, fins, head and other physical characteristics are similar to each other, errors often occur in the process of identifying the type of tilapia when done by humans. Therefore, this research will use computational methods to assist in identifying fish morphology by identifying the morphology or physical characteristics of 12 varieties of tilapia and overcoming errors that often occur in the identification process by applying the edge detection method. This technique will improve image quality and identification accuracy through the Deep Learning algorithm, by optimizing the feature extraction process in the Deep Learning algorithm through edge detection, proven to be 0.9 but the lowest accuracy value was obtained in sobel edge detection combined with LSTM, namely 0.12. It is hoped that this research will increase accuracy and efficiency in identifying the morphology of tilapia fish. This will help experts carry out morphological analysis of tilapia fish more quickly and effectively

Keywords: *Oreochromis niloticus; Deep learning; Identification; Image processing*

Abstrak

Ikan nila adalah spesies ikan yang dianggap invasif di seluruh dunia, tetapi memiliki nilai ekonomis yang tinggi di Indonesia karena ketahanannya terhadap lingkungan dan popularitasnya. Ada 12 varietas unggul ikan nila yang ingin diidentifikasi dalam penelitian ini, karena bentuk tubuh ikan, sirip, kepala dan ciri fisik lainnya mirip satu sama lain maka sering terjadi kesalahan dalam proses identifikasi jenis ikan nila jika dilakukan oleh manusia. Oleh karena itu penelitian ini akan menggunakan metode komputasi untuk membantu dalam identifikasi morfologi ikan dengan untuk melakukan identifikasi morfologi atau ciri fisik dari 12 varietas ikan nila serta mengatasi kesalahan yang sering terjadi dalam proses identifikasi dengan menerapkan metode deteksi tepi. Teknik ini akan meningkatkan kualitas citra dan akurasi identifikasi melalui algoritma *Deep Learning*, dengan mengoptimalkan proses ekstraksi ciri pada algoritma *Deep Learning* melalui deteksi tepi, terbukti 0,9 namun nilai akurasi terendah didapatkan pada deteksi tepi sobel yang digabungkan dengan LSTM yaitu sebesar 0,12. Penelitian ini diharapkan akan meningkatkan akurasi dan efisiensi dalam identifikasi morfologi ikan nila. Ini akan membantu para ahli dalam melakukan analisis morfologi ikan nila secara lebih cepat dan efektif.

Kata kunci: *Ikan nila; Deep learning; Identifikasi; Pengolahan citra*

1. Pendahuluan

Ikan nila merupakan salah satu spesies ikan yang dinilai cukup invasif diseluruh dunia[1], meskipun demikian ikan nila merupakan jenis ikan air tawar yang memiliki nilai ekonomis yang cukup tinggi di Indonesia[2], hal ini disebabkan oleh beberapa faktor ketahanan ikan nila terhadap lingkungan yang cukup baik, ikan nila merupakan ikan yang cukup digemari oleh kebanyakan masyarakat Indonesia, sehingga ikan ini memiliki nilai ekonomis yang baik. Di Indonesia sejauh ini ikan nila memiliki 12 varietas unggul yang umum dikonsumsi oleh masyarakat diantaranya Nila

Salina, Nila Anjani, Nila Best, Nila Gesit, Nila Jatimbulan, Nila Jica, Nila Larasati, Nila Merah Nilasa, Nila Nirwana, Nila Pandukunti, Nila Srikandi dan Nila Sultana[3]. Pada penelitian ini kami akan melakukan identifikasi 12 varietas tersebut untuk mengetahui morfologi atau ciri fisik dari masing-masing varietas.

Identifikasi morfologi ikan, pada umumnya dilakukan dengan cara mengamati dan memperhatikan bentuk tubuh pada ikan mulai dari betuk sirip, bentuk, kepala dorsal dan ciri fisik lain[4][5], aktifitas pengamatan ini biasanya dilakukan oleh ahli yang memiliki pengetahuan khusus tentang morfologi ikan tersebut[6][7], namun pada kenyataanya kesalahan seringkali terjadi dalam proses identifikasinya, seperti kesalahan karena subjektivitas dan penglihatan pada manusia[8], oleh karena itu dalam penelitian ini kami mengajukan sebuah metode komputasi yang dapat digunakan untuk membantu manusia dalam melakukan identifikasi morfologi ikan, dengan melakukan pengolahan pada 12 varietas citra ikan nila.

Beberapa pengolahan citra untuk melakukan identifikasi morfologi pada citra ikan[8][9] telah banyak dilakukan oleh peneliti didunia[10], salah satunya penerapan algoritma *deep learning*[10][11], algoritma tersebut dapat digunakan untuk membantu proses identifikasi morfologi ikan sehingga proses identifikasi dapat dilakukan dengan lebih cepat, namun pada prosesnya algoritma *deep learning* memiliki permasalahan dalam akurasi hasil identifikasinya[8][12], salah satu penyebab permasalahan tersebut adalah dalam proses ekstraksi ciri dari objek citra yang seringkali tidak dapat terdeteksi dengan baik.


Dalam penelitian ini, akan dilakukan optimalisasi algoritma *deep learning* dengan menggunakan deteksi tepi pada identifikasi morfologi ikan Nila. Deteksi tepi adalah teknik pengolahan citra digital yang digunakan untuk mengidentifikasi tepi objek pada citra[13], Teknik deteksi tepi akan digunakan untuk memperbaiki kualitas citra dari 12 varietas ikan Nila sehingga proses ekstraksi ciri citra tersebut menjadi lebih baik dan berdampak pada peningkatan akurasi hasil dari algoritma *deep learning*[14].

Diharapkan dengan optimalisasi pada proses ekstraksi ciri pada algoritma *deep learning* ini, hasil identifikasi morfologi ikan Nila akan menjadi lebih akurat dan efisien, sehingga dapat membantu para ahli dalam melakukan analisis morfologi ikan Nila dengan lebih cepat dan efektif.

2. Metode Penelitian

2.1. Kerangka Penelitian

Penelitian ini mengembangkan sebuah algoritma dalam pengenalan citra untuk identifikasi jenis ikan nila berdasarkan perbedaan ciri bentuk tubuh (morfologi) pada spesifik jenis ikan nila, agar mendapat gambaran proses penelitian kami akan sajikan kerangka penelitian yang akan disajikan pada gambar 1



Gambar 1. Kerangka Penelitian

Gambar 1 menunjukkan kerangka penelitian serta tahapan-tahapan yang digunakan dalam penelitian ini, mulai dari preprocessing, implementasi algoritma, evaluasi serta penemuan model terbaik dengan akurasi tertinggi dari masing-masing percobaan.

Proses penelitian dimulai dari pengumpulan data berupa citra, kemudian citra dilakukan pra-pemrosesan dengan melakukan perubahan citra kedalam ukuran 256x256 dan citra grayscale, setelah selesai dilakukan pra-pemrosesan, selanjutnya masing-masing citra dilakukan pendeteksian tepi untuk selanjutnya masuk kedalam proses deep learning dengan algoritma CNN, LSTM dan RNN ketiga algoritma *deep-learning* ini kemudian dibandingkan nilai MSE, *accuracy*, *F1 Score*, *Avg Precission* dan *Avg Reccall* untuk mencari algoritma terbaik.

2.2. Dataset

Dalam penelitian ini kami menggunakan dataset yang diambil dari kementrian kelautan dan perikanan republik Indonesia, melalui data center nya yang dapat diakses pada laman <http://sisinbe.kkp.go.id/web/varietas/12?jenis=4>. Pada *datacenter* tersebut kami mengambil sejumlah sample citra ikan, dengan jenis yang spesifik yaitu *Oreochromis niloticus* yang seluruhnya terdapat diperaian Indonesia, terdapat 12 varietas ikan yang akan kami gunakan sebagai bahan penelitian. Pada Gambar 2. Jenis dan citra ikan akan ditampilkan sebagai bahan referensi.



Nila Gesit



Nila Salina



Nila Larasati



Nila Jatimbulan



Nila Anjani



Nila Merah Nilasa



Nila Jica



Nila BEST



Nila Nirwana



Nila srikandi



Nila Pandu-Kunti



Nila Nirwana II

Gambar 2. Citra Jenis Ikan Nila

Gambar 2 menunjukkan citra dari 12 jenis ikan nila yang digunakan dalam penelitian ini. Dari total 12 citra jenis ikan nila tersebut selanjutnya kami akan melakukan proses deteksi tepi untuk dilakukan identifikasi terhadap morfologi dari masing-masing citra tersebut.

2.3. Algoritma Penelitian

2.3.1. Algoritma Deteksi Tepi

Deteksi tepi merupakan salah satu tahap dalam proses pengolahan citra. Proses deteksi tepi merupakan proses identifikasi batas-batas yang memisahkan objek yang terdapat dalam citra dengan latar belakang. Tujuan dari deteksi tepi ini adalah menemukan perubahan yang signifikan dalam intensitas piksel antara dua area yang berbeda dalam suatu citra. Perubahan ini menandakan adanya batas atau tepi pada objek. Beberapa Teknik deteksi tepi yang kami gunakan dalam penelitian ini adalah:

1) Sobel

Pada deteksi sobel mempergunakan matrix yang berukuran 3x3, sobel menerapkan matrix mask yang berukuran $n \times n$ yang sama dengan matrik neighbor. Metode ini menggunakan kernel Sobel untuk menghitung gradien citra dalam dua arah (horizontal dan vertikal) dan kemudian hasil perhitungan tersebut digabungkan untuk menemukan tepi [15].

-1	0	1	-1	-2	-1
-2	0	2	0	0	0
-1	0	1	1	2	1

Gambar 3. Matrix pada Sobel

Gambar 3 merupakan contoh matrix yang terbentuk dari teknik deteksi tepi sobel, matrix ini berukuran 3x3 lalu nantinya akan dihitung gradien citra dalam dua arah.

2) Canny

Deteksi tepi canny merupakan sebuah algoritma deteksi tepi yang telah populer dan canggih. Dalam deteksi tepi *canny* melibatkan beberapa tahapan, diantaranya proses konvolusi menggunakan kernel Gaussian, deteksi gradien, pencairan tepi, dan deteksi *non-maximum* deteksi tepi canny memiliki beberapa tahapan diantaranya [15]:

a. Smoothing

Citra akan dihaluskan dengan metode *Gaussian smoothing*. Yang memiliki tujuan mengurangi noise dalam citra dan menghasilkan citra yang lebih halus.

b. Deteksi Gradien

Setelah penghalusan, selanjutnya citra gradien dihitung dengan algoritma deteksi gradien. Proses ini dilakukan dengan menerapkan operator Sobel atau operator lainnya dalam mengukur perubahan intensitas piksel dalam arah horizontal dan vertikal. Gradien ini memberikan informasi tentang di mana perubahan yang signifikan terjadi dalam citra.

c. Pencarian Tepi

Setelah gradien diketahui selanjutnya dicari setiap tepi, tahapan ini bertujuan untuk menghilangkan piksel-piksel yang bukan tepi yang sebenarnya. Algoritma ini melakukan pencairan tepi dengan menggabungkan piksel-piksel yang terhubung dengan tepi yang jelas dan menghilangkan tepi2 yang kurang jelas.

d. Deteksi Tepi Non-Maximum

Deteksi tepi *non-maximum* adalah langkah kritis dalam algoritma Canny. Ini melibatkan perbandingan nilai gradien di sekitar setiap piksel untuk menentukan apakah piksel tersebut adalah piksel tepi yang sesungguhnya. Piksel yang memiliki

gradien tertinggi dalam arah tertentu dianggap sebagai tepi, sedangkan yang lainnya dihapus.

e. Histeresis

Histeresis adalah langkah terakhir dalam algoritma *Canny* yang membantu memfilter piksel-piksel tepi berdasarkan ambang batas atas dan ambang batas bawah. Piksel yang memiliki nilai gradien di atas ambang batas atas dianggap sebagai piksel tepi kuat, sedangkan piksel dengan nilai gradien di antara ambang batas atas dan ambang batas bawah dianggap sebagai piksel tepi lemah. Piksel-piksel tepi lemah yang terhubung dengan piksel tepi kuat akan dianggap sebagai bagian dari tepi yang sesungguhnya.

3) Prewitt

Metode ini mirip dengan Sobel tetapi menggunakan kernel Prewitt untuk menghitung gradien citra.

4) Roberts

Ini adalah metode sederhana yang menggunakan kernel Roberts untuk mendeteksi tepi dalam citra.

5) *Laplacian of Gaussian* (LoG)


Metode ini menggabungkan operasi *Gaussian smoothing* dengan deteksi tepi *Laplacian* untuk menemukan tepi dalam citra.

2.3.2. Algoritma Deep Learning

Deep learning merupakan sebuah algoritma yang memanfaatkan arsitektur dari jaringan saraf tiruan/jst. Dalam penelitian ini beberapa algoritma [9] deep learning akan diterapkan diantaranya:

1) CNN

CNN merupakan sebuah arsitektur multi layer perceptron yang dibangun khusus untuk menanggapi image, yang terinspirasi dari jaringan otak pada manusia [16]




Gambar 4. Desain Arsitektur CNN

Gambar 4 menunjukkan desain arsitektur dari algoritma CNN yang menunjukkan proses kinerja algoritma mulai dari proses *image input*, *filtering*, *layering*, sampai dengan *classification* dan hasil outputnya

2) LSTM

Long Short-Term Memory merupakan salah satu jenis jaringan saraf rekurens (RNN) yang dirancang khusus untuk mengatasi masalah depedensi (*long-term dependencies*) dalam pemrosesan urutan data. LSTM memecahkan masalah utama yang dihadapi oleh jaringan saraf rekurens tradisional, yaitu masalah *vanishing gradient* (gradien yang hilang) dan *exploding gradient* (gradien yang meledak). Masalah ini terjadi ketika model RNN mencoba untuk memperbarui bobotnya selama pelatihan dengan urutan data yang panjang [11]




Gambar 5. Arsitektur LSTM

Gambar 5 menunjukkan arsitektur dari algoritma LSTM, arsitektur ini menunjukkan tahapan alur kinerja algoritma dalam memecahkan suatu masalah.

3) RNN

RNN (*Recurrent Neural Network*) merupakan jenis arsitektur jaringan saraf tiruan yang dirancang khusus untuk memproses urutan data. Keunikan utama RNN adalah kemampuannya untuk menjaga keadaan internal (*hidden state*) yang berfungsi sebagai memori sementara untuk informasi yang diterima sebelumnya dalam urutan [17]



Gambar 6. Arsitektur RNN

Gambar 6 menunjukkan arsitektur dari algoritma RNN yang menunjukkan alur kinerja algoritma RNN dalam menyelesaikan suatu masalah.

2.4. Evaluasi Model

Pada penelitian ini kami melakukan evaluasi model menggunakan beberapa metode pengukuran seperti.

1. Precision

Precision merupakan perbandingan antara nilai *True Positif* (TP) dengan jumlah data yang diprediksi positif, maka persamaannya dapat ditulis

$$precision = \frac{TP}{TP + FP}$$

2. Recall

Sedangkan untuk *Recall* dapat diartikan sebagai perbandingan antara *True Positif* (TP) dan jumlah data yang sebenarnya positif, maka persamaan yang dapat ditulis adalah

$$recall = \frac{TP}{TP + FN}$$

3. F1-Score

F1-score biasa juga disebut *harmonic mean* dari *precision* dan *recall*, atau dapat ditulis dalam persamaan berikut

$$\frac{1}{F1} = \frac{1}{2} \left(\frac{1}{precision} + \frac{1}{recall} \right)$$

Manakala nilai F1- Score dikatakan baik adalah memiliki nilai 1.0 dan dikatakan buruk adalah 0, dikatakan hasil F1-Score baik berarti Model klasifikasi kita punya *precision* dan *recall* yang baik.


3. Hasil dan Pembahasan

Hasil pengolahan algoritma dan optimalisasi yang didapatkan pada penelitian ini akan disajikan pada tabel 1, selain pada tabel 1, kami juga akan mendeskripsikan hasil tersebut kedalam narasi dan bentuk grafik pada gambar 7, metode evaluasi yang kami gunakan dalam penelitian ini meliputi rata-rata akurasi, *f1 score* pada gambar, *precision* dan *recall* persamaan untuk metode evaluasi yang telah kami sajikan pada point sebelumnya.

Tabel 1. Hasil Evaluasi Model Algoritma *Deep Learning* dengan Deteksi Tepi

No	Algoritma	Edge Detection	Accuracy	F1 Score	Avg Precision	Avg. Recall
1	CNN	Normal	0,8	0,78	0,7	0,71
		Canny	0,9	0,8	0,76	0,77
		Sobel	0,72	0,62	0,7	0,62
		Laplacian	0,65	0,66	0,6	0,6
2	LSTM	Original	0,2	0,13	0,17	0,17
		Canny	0,3	0,2	0,2	0,2
		Sobel	0,15	0,1	0,14	0,12
		Laplacian	0,23	0,2	0,1	0,15
3	RNN	Original	0,6	0,58	0,3	0,45
		Canny	0,5	0,47	0,34	0,33
		Sobel	0,5	0,51	0,4	0,45
		Laplacian	0,2	0,12	0,2	0,3

Tabel 1 menunjukkan hasil pengolahan data citra ikan nila yang telah diolah menggunakan algoritma *deep learning* dengan deteksi tepi, hasil evaluasi ditunjukkan dengan nilai akurasi, *F1-Score*, *Precision* dan *Recall*. Selain dengan tabel, hasil evaluasi juga ditunjukkan dalam bentuk grafik sebagai berikut:



Gambar 7. Grafik Hasil Pengujian Model Dengan penambahan Deteksi Tepi

Gambar 7 menunjukkan hasil bahwa deteksi tepi *canny* yang di gabungkan dengan CNN memiliki nilai akurasi paling tinggi yaitu sebesar 0,9 namun nilai akurasi terendah didapatkan pada deteksi tepi sobel yang digabungkan dengan LSTM yaitu sebesar 0,12. Penggunaan *Convolutional Neural Network* (CNN) yang digabungkan dengan deteksi tepi Canny dalam penelitian ini telah terbukti menghasilkan hasil yang lebih baik dibanding dengan daripada menggunakan CNN saja dalam penelitian yang telah dilakukan [1][15], pada penelitian tersebut ditemukan beberapa kekurangan dari CNN tanpa menggunakan deteksi tepi akan rentan terhadap distorsi dan gangguan betuk pada objek citra yang di identifikasi.

4. Kesimpulan

Kelayakan model deteksi tepi yang digunakan dalam optimalisasi hasil algoritma deep Learning seperti CNN, LSTM dan RNN telah kami eksplorasi untuk beberapa kemungkinannya. Penerapan deteksi tepi dalam algoritma *deep learning* menunjukan hasil yang beragam pada setiap algoritma nya dengan ini deteksi tepi berdampak pada peningkatan ataupun penurunan pada nilai akurasi setiap algoritma. Penelitian ini menunjukkan kemampuan penggunaan deteksi tepi yang diterapkan pada model deep learning untuk mengidentifikasi ikan nila (*Oreochromis Niloticus*). Performa masing-masing model yang diuji memperoleh hasil yang beragam. Performa yang beragam pada masing-masing model didapat dengan mengombinasikan beberapa metode deteksi tepi seperti (*Canny*, *Sobel*, dan *Laplacian*). Berdasarkan hasil pengujian maka memperoleh performa terbaik pada dataset yang digunakan, dengan akurasi tertinggi mencapai 0,9 pada Metode deteksi tepi canny yang ditambahkan kedalam algoritma CNN. Namun, penelitian lebih lanjut masih diperlukan untuk meningkatkan efisiensi waktu. Penelitian selanjutnya akan berfokus pada Pengembangan dataset 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 Referensi

- [1] L. S. Yamasaki *et al.*, "Identification of Nile tilapia (*Oreochromis niloticus*) and its hybrids in natural environments in Hawaii," *Aquaculture*, vol. 550, pp. 737–805, Mar. 2022, doi: 10.1016/j.aquaculture.2021.737805.
- [2] P. P. Debnath, M. D. Jansen, J. Delamare-Deboutteville, C. V. Mohan, H. T. Dong, and C. Rodkhum, "Is tilapia mortality a latent concern for the aquaculture sector of Bangladesh? An epidemiology and health economic impact study," *Aquaculture*, vol. 560, no. 1, pp. 73–86, Nov. 2022, doi: 10.1016/j.aquaculture.2022.738607.
- [3] Kementerian Kelautan dan Perikanan, "Varietas Ikan Nila Indoensia," Kementerian Kelautan dan Perikanan. Accessed: Oct. 30, 2023. [Online]. Available: <http://sisinbe.kkp.go.id/>

- [4] H. Santoso, S. Laili, and J. Biologi, "Kajian Morfologi Ikan Nila (*Oreochromis niloticus*) dalam Habitat Air Tawar dan Air Payau," *Jurnal Ilmiah Biosaintropis (Bioscience-Tropic*, vol. 3, no. 1, pp. 10–17, 2018, Accessed: Oct. 30, 2023. [Online]. Available: <https://biosaintropis.unisma.ac.id/index.php/biosaintropis/article/view/146>
- [5] O. Zenal Arifin and T. Kurniasih, "Karakterisasi Morfologi Keturunan Pertama Ikan Nila (*Oreochromis Niloticus*) Get Dan Gift Berdasarkan Metode Truss Morphometrics," *Jurnal Riset*, vol. 2, no. 3, pp. 373–383, 2019.
- [6] E. Deni Nugroho, D. Anggorowati Rahayu, and D. Rupa, "Studi Morfologi Ikan Mudskippers (*Gobiidae: Oxudercinae*) Sebagai Upaya Karakterisasi Biodiversitas Lokal Pulau Tarakan," *Jurnal Harpodon Borneo*, vol. 9, no. 1, pp. 46–57, 2016, doi: <https://doi.org/10.35334/harpodon.v9i1.49>.
- [7] A. Purnama, S. Bahri, G. Gunawan, T. Hidayatulloh, and S. Suhada, "Implementation of Deep Learning for Handwriting Imagery of Sundanese Script Using Convolutional Neural Network Algorithm (CNN)," *ILKOM Jurnal Ilmiah*, vol. 14, no. 1, pp. 10–16, Apr. 2022, doi: 10.33096/ilkom.v14i1.989.10-16.
- [8] N. Petrellis, "Measurement of Fish Morphological Features through Image Processing and Deep Learning Techniques," *Applied Sciences*, vol. 11, no. 10, pp. 1–23, May 2021, doi: 10.3390/app11104416.
- [9] A. Saleh, M. Sheaves, and M. Rahimi Azghadi, "Computer vision and deep learning for fish classification in underwater habitats: A survey," *Fish and Fisheries*, vol. 23, no. 4, pp. 977–999, Jul. 2022, doi: 10.1111/faf.12666.
- [10] M. Sun, X. Yang, and Y. Xie, "Deep Learning in Aquaculture: A Review," *J Comput (Taipei)*, vol. 31, no. 1, pp. 294–319, 2020, doi: 10.3966/199115992020023101028.
- [11] M. Jahanbakht, W. Xiang, N. J. Waltham, and M. R. Azghadi, "Distributed Deep Learning and Energy-Efficient Real-Time Image Processing at the Edge for Fish Segmentation in Underwater Videos," *IEEE Access*, vol. 10, pp. 117796–117807, 2022, doi: 10.1109/ACCESS.2022.3202975.
- [12] H. C. Altunay and Z. Albayrak, "A hybrid CNN+LSTM-based intrusion detection system for industrial IoT networks," *Engineering Science and Technology, an International Journal*, vol. 38, pp. 101–322, Feb. 2023, doi: 10.1016/j.jestch.2022.101322.
- [13] R. Rizal Adi Saputra, R. Reskal, and F. Mimi Wahyuni, "Segmentasi Pada Plat Kendaraan Dinas Dengan Metode Deteksi Tepi Canny, Prewitt, Sobel, & Roberts," *Jurnal Sains Komputer & Informatika (J-SAKTI)*, vol. 6, no. 1, pp. 328–339, 2022, doi: <http://dx.doi.org/10.30645/j-sakti.v6i1.448>.
- [14] Md. M. Islam, Md. Z. Islam, A. Asraf, M. S. Al-Rakhami, W. Ding, and A. H. Sodhro, "Diagnosis of COVID-19 from X-rays using combined CNN-RNN architecture with transfer learning," *BenchCouncil Transactions on Benchmarks, Standards and Evaluations*, vol. 2, no. 4, pp. 2–11, Oct. 2022, doi: 10.1016/j.tbench.2023.100088.
- [15] H. Masuda, T. Jukei, and T. Hasegawa, "Fish Species Identification Using a CNN-based Multimodal Learning Method," in *Proceedings of the 2020 2nd International Conference on Image, Video and Signal Processing*, in IVSP '20. New York, NY, USA: ACM, Mar. 2020, pp. 15–19. doi: 10.1145/3388818.3389164.