

KLASIFIKASI MOLTING KEPITING SOKA MENGGUNAKAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK*

Ali Khumaidi¹, Aini Nurpadilah²

^{1,2} Prodi Teknik Informatika, Universitas Krisnadwipayana
Jl. Kampus Unkris, Jatiwaringin, Jakarta
E-mail : alikhumaidi@unkris.ac.id¹

Abstrak

Kepiting Soka memiliki nilai ekonomi tinggi karena seluruh bagian tubuhnya dapat dimakan selama fase molting, saat cangkangnya lunak. Proses ini berlangsung singkat, hanya sekitar 5 jam sebelum cangkang mengeras kembali. Deteksi molting secara otomatis sangat diperlukan untuk mengoptimalkan waktu panen dan mencegah kehilangan produksi. Teknologi deep learning menggunakan arsitektur *MobileNetV2* telah menunjukkan efisiensi dalam klasifikasi gambar. Penelitian ini bertujuan untuk mengklasifikasi kepiting soka dalam kondisi molting menggunakan arsitektur *MobileNetV2*, berbeda dengan metode pembelajaran mesin sebelumnya. *MobileNetV2* dipilih karena kemampuannya dalam klasifikasi citra dengan sumber daya komputasi terbatas. Dataset berisi 260 citra kepiting, dengan fokus pada kepiting soka molting dan tidak molting, diproses melalui augmentasi, resize, dan pembagian data (80% data training, 10% validasi, dan 10% testing). Model ini menghasilkan akurasi tinggi pada pelatihan dan validasi sebesar 100%, membuktikan kemampuannya untuk mendeteksi kepiting molting secara efisien dan model tidak mengalami overfitting. Arsitektur *MobileNetV2* berpotensi untuk diaplikasikan dalam sistem klasifikasi kepiting soka berbasis perangkat seluler.

Kata kunci : CNN, Kepiting Soka, Klasifikasi, *MobileNetV2*.

Abstract

Soka crabs have a high economic value because all parts of the body are edible during the molting phase, when the shell is soft. This process is short, only about 5 hours before the shell hardens again. Automatic molting detection is necessary to optimise harvesting time and prevent production loss. Deep learning technology using MobileNetV2 architecture has shown efficiency in image classification. This study aims to classify soka crabs in molting state using MobileNetV2 architecture, in contrast to previous machine learning methods. MobileNetV2 was chosen for its capability in image classification with limited computational resources. A dataset of 260 crab images, focusing on molting and non-molting soka crabs, was processed through augmentation, resizing, and data sharing (80% training, 10% validation, and 10% testing data). The model produced high accuracy in training and validation of 100%, proving its ability to detect molting crabs efficiently and the model did not suffer from overfitting. The MobileNetV2 architecture has the potential to be applied in a mobile-based soka crab classification system.

Keywords : CNN, Classification, *MobileNetV2*, Soka Crab.

1. PENDAHULUAN

Kepiting Soka, juga dikenal sebagai *soft shell crab*, adalah salah satu komoditas perikanan bernilai ekonomi tinggi. Keunikan kepiting ini terletak pada fase molting, ketika cangkangnya menjadi lunak dan seluruh bagian tubuhnya dapat dikonsumsi [1]. Daging dari kepiting ini memiliki kandungan lemak jenuh yang rendah, tinggi protein, serta mengandung berbagai mineral dan vitamin. Selain itu, terdapat kandungan selenium yang memiliki peran penting dalam mencegah kanker dan meningkatkan daya tahan tubuh terhadap infeksi virus dan bakteri [2]. Molting merupakan proses ganti kulit yang menjadikan bagian terluar tubuh pada kepiting dan kerabatnya menjadi sangat lunak dan berbeda dari biasanya [3]. Fase *molting* sangat penting karena jika tidak segera dipanen, cangkang kepiting akan mengeras kembali dalam waktu sekitar 5 jam. Oleh karena itu, pengenalan molting pada kepiting Soka menjadi kritis untuk menghindari kehilangan produksi akibat keterlambatan pemanenan. Untuk menghadapi tuntutan pasar yang terus berkembang dan meningkatkan efisiensi produksi, salah satu strategi pengelolaan budidaya kepiting soka adalah melalui sistem apartemen [4], di mana kepiting dipelihara dalam kotak-kotak individu untuk

memantau molting. Teknologi *artificial intelligence* (AI) menawarkan solusi untuk masalah ini melalui deteksi otomatis molting menggunakan model klasifikasi gambar [5].

Hasil observasi dan wawancara dengan mitra di IPB *Fisheries and Marine Observation Station* (IFMOS) menunjukkan bahwa terdapat 3000 box kepiting. Setiap 4 jam, satu operator memeriksa 70 box dalam waktu 20 menit. Berdasarkan hal ini, dibutuhkan sekitar 14 jam 20 menit untuk memeriksa 3000 box jika hanya ada satu operator. Jika kepiting soka atau kepiting cangkang lunak tidak segera dipanen, cangkangnya akan kembali mengeras setelah 5 jam. Hal ini menunjukkan bahwa budidaya di apartemen kepiting IFMOS kurang efektif dan efisien. Masalah efisiensi waktu dan kelelahan operator dapat mengakibatkan kehilangan kepiting soka karena keterlambatan pengecekan dan pemanenan. Normalnya, dibutuhkan 10 operator untuk mengelola 3000 box, sehingga biaya upah kerja menjadi cukup tinggi. Sistem apartemen ini diidentifikasi sebagai evolusi ketiga setelah budidaya di alam dan budidaya sistem horizontal yang umumnya menggunakan tambak [6]. Apartemen kepiting IFMOS dapat dilihat pada Gambar 1.



Gambar 1. Sistem pembiakan apartemen kepiting.

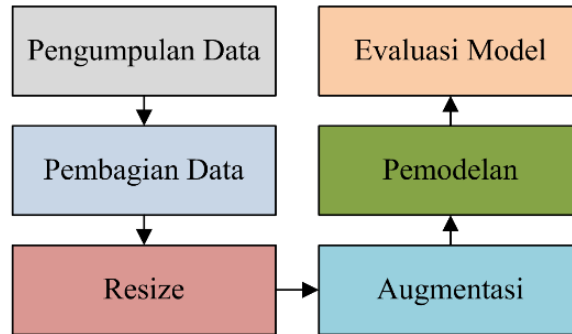
Proses pengelolaan budidaya kepiting soka melibatkan berbagai aspek, dan salah satu kunci pentingnya adalah pengelolaan kualitas lingkungan [7]. Hal ini bertujuan untuk menciptakan habitat yang optimal bagi kehidupan kepiting soka. Dalam usaha meningkatkan produksi kepiting soka, penerapan *artificial intelligence* menjadi pilihan yang menarik. Salah satu pendekatan yang bisa diambil dengan menggunakan klasifikasi *deep learning* menggunakan *TensorFlow* dan algoritma *Convolutional Neural Network* (CNN). Dengan memanfaatkan teknologi ini, pemantauan terhadap fase *molting* kepiting soka dapat dilakukan secara lebih efektif dan pengambilan keputusan yang lebih akurat dalam manajemen budidayanya [8].

Terdapat hasil penelitian klasifikasi molting kepiting dengan AI menggunakan pendekatan *machine learning* yakni perbandingan kinerja algoritma *K-Nearest Neighbors* (KNN), *Support Vector Machine* (SVM), dan *Random Forest Classifier* (RFC) [9], pendekatan *deep learning* menggunakan YOLOv3 yang disempurnakan berhasil mendeteksi *molting* kepiting dalam air bersih memiliki kinerja yang lebih baik dibandingkan dalam keadaan air keruh [10], penyempurnaan YOLOv5 yang dinamakan YOLOF memiliki kinerja lebih baik mencapai peningkatan 5.4% dalam presisi rata-rata rata-rata dalam deteksi cangkang [11]. Penelitian deteksi jenis kelamin kepiting dengan pendekatan *machine learning* berhasil dengan baik dengan pengolahan citra, logika fuzzy, dan pengklasifikasi KNN [12] dan pendekatan *deep learning* juga memiliki presisi 96,75% dengan penyempurnaan YOLOv4 [13]. Walaupun algoritma *machine learning* berhasil mengklasifikasi kepiting *molting* dan tidak *molting* namun pendekatan *deep learning* dengan CNN menunjukkan hasil yang lebih baik dalam klasifikasi gambar, terutama pada gambar yang lebih kompleks. Arsitektur CNN seperti YOLO telah diterapkan namun memiliki model yang lebih besar dan membutuhkan komputasi lebih tinggi [14]. Untuk mengatasi masalah ini, arsitektur *MobileNet* dipilih dalam penelitian ini karena ukurannya yang relatif kecil dan kemampuannya yang efisien dalam melakukan klasifikasi gambar pada perangkat dengan sumber daya terbatas [15]. Penelitian penerapan arsitektur *MobileNet* dalam klasifikasi citra memiliki kinerja yang sangat baik, diantaranya identifikasi klasifikasi tulang implan pada irisan CBCT dan dapat membantu dokter dalam menetapkan diagnosis praoperasi dan rencana perawatan yang andal untuk implan gigi dengan akurasi 84% hingga 99,21% [16], diagnosis tuberkulosis dari dataset citra X-ray dengan akurasi hingga 98,66% [17], dan mengklasifikasi cacat permukaan pada permukaan silinder berongga seperti pipa dan tong menggunakan algoritma *single shot detection* dan *MobileNet*. Penerapan algoritma berhasil mengklasifikasi 5 kelas masalah yaitu pengelupasan, pengelupasan, pengaratn, kotoran, dan retakan termal [18].

Penelitian ini bertujuan untuk membangun model klasifikasi kepiting soka dalam fase *molting* dan tidak *molting* menggunakan arsitektur CNN *MobileNetV2*. Kontribusi penelitian ini adalah pemodelan arsitektur *MobileNetV2* dalam deteksi *molting* kepiting soka dengan akurasi tinggi dan efisiensi komputasi yang memadai untuk diterapkan pada *perangkat* seluler.

2. METODOLOGI

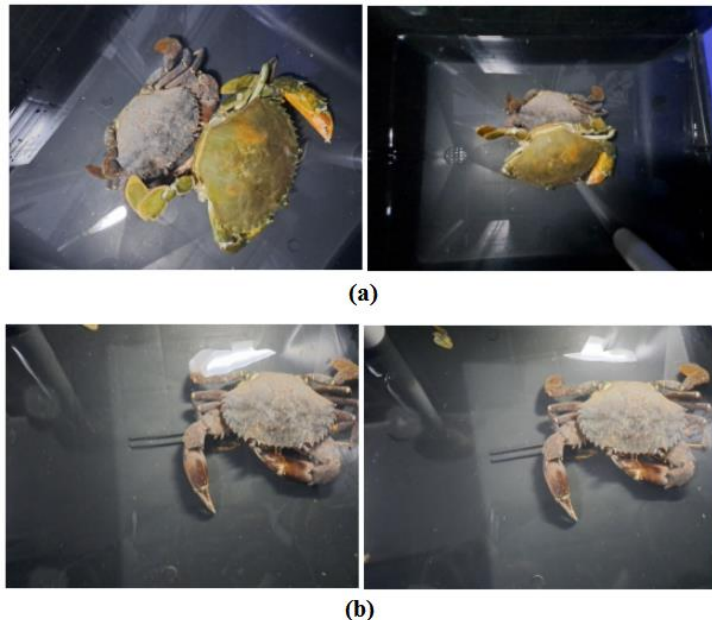
Penelitian ini mencakup beberapa tahapan, seperti pengumpulan data, pembagian data, *resize*, augmentasi, pemodelan menggunakan CNN *MobileNetV2*, dan evaluasi model, sebagaimana ditunjukkan pada Gambar 2.



Gambar 2. Tahapan penelitian.

1. Tahap Pengumpulan Data

Data citra dikumpulkan menggunakan kamera handphone dari pembiakan sistem apartemen pada IPB *Fisheries and Marine Observation Station* (IFMOS). Dataset terdiri dari dua jenis citra kepiting soka yaitu *molting* dan tidak *molting* dengan jumlah masing-masing 130 citra. Gambar 3a dan 3b memberikan representasi visual dari citra-citra yang terdapat dalam dataset, menampilkan variasi dalam kondisi dan karakteristik kepiting soka *molting* dan tidak *molting*. Pada Gambar 3a terlihat ada dua kepiting, disampingnya adalah cangkang setelah pergantian.



Gambar 3. Kepiting Soka *Molting* (a), Tidak *Molting* (b).

2. Tahap Pembagian Data

Tahap ini membagi data menjadi beberapa bagian yaitu data *training*, *validation* dan *testing*, setiap bagian memiliki fungsi yang berbeda dalam proses membangun model. Data *training* berfungsi untuk melatih model saat proses *epoch* berlangsung, data *validasi* berfungsi untuk mengevaluasi model saat

pelatihan berlangsung, dan data testing berfungsi untuk menguji model terlatih. Rasio split data yang digunakan yaitu 80:10:10.

3. Tahap Resize

Resize adalah tahap citra mengalami penyesuaian dimensi, perubahan skala dari citra asli dengan ukuran beragam menjadi citra berukuran tetap. Dengan mengubah ukuran citra, kita dapat mengoptimalkan penggunaan sumber daya dan mempercepat proses pemrosesan. Pada tahap ini citra yang ada diubah menjadi ukuran 255 x 255 untuk semua metode fitur ekstraksi.

4. Tahap Augmentasi

Augmentasi merupakan tahapan pra-pemrosesan dengan memodifikasi atau memanipulasi data untuk memperbanyak data sehingga performa model akan meningkat [19]. Augmentasi bertujuan untuk menambah citra data latih sebelum diproses pada algoritma CNN. Proses augmentasi dilakukan dengan menggunakan *TensorFlow Image Data Generator* yang memungkinkan rotasi gambar sebesar 40°. Augmentasi dilakukan sebanyak 8 kali untuk setiap gambar dalam dataset.

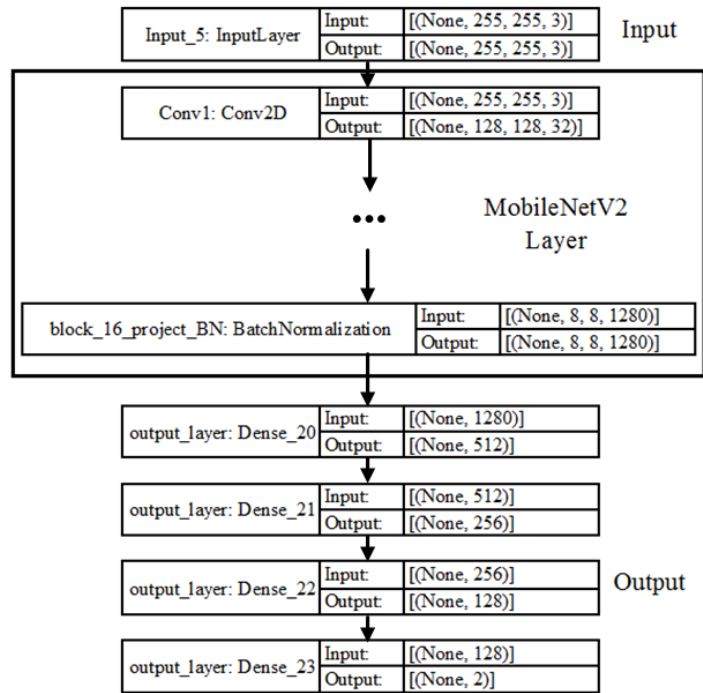
5. Tahap Pemodelan

Pemodelan meliputi pengembangan dan pelatihan model untuk melakukan klasifikasi pada citra kepingit soka. Pada tahap ini digunakan algoritma CNN, arsitektur CNN yang umum terdiri dari lapisan konvolusi, lapisan *pooling*, dan lapisan *fullconnected*. Lapisan konvolusi bertanggung jawab untuk mengekstraksi fitur-fitur penting dari citra, lapisan *pooling* digunakan untuk mereduksi dimensi spasial citra, dan lapisan yang terhubung sepenuhnya berfungsi untuk menghubungkan hasil ekstraksi fitur ke keluaran yang dapat diinterpretasikan. Arsitektur *CNN MobilenetV2* menunjukkan pendekatan yang efisien dalam penggunaan sumber daya komputasi. *MobilenetV2* adalah salah satu arsitektur CNN yang dikembangkan oleh Google, dirancang khusus untuk aplikasi di perangkat mobile dan lingkungan sumber daya terbatas. Arsitektur model *neural network* menggunakan *MobileNetV2* sebagai bagian ekstraktor fitur (base model) dan menambahkan beberapa layer di atasnya [20]. Arsitektur *MobileNetV2* dapat dilihat pada Gambar 4 dan berikut rincian pola dari model:

1. `mbnet_v2.output`: Mengambil output dari layer terakhir *MobileNetV2* sebagai input untuk layer berikutnya.
2. `tf.keras.layers.GlobalAveragePooling2D()`: Melakukan *global average pooling* untuk mengurangi dimensi spasial dan menghasilkan nilai rata-rata dari setiap channel fitur.
3. `tf.keras.layers.Dense(512, activation='relu')`: Layer Dense dengan 512 *neuron* dan fungsi aktivasi ReLU.
4. `tf.keras.layers.Dense(256, activation='relu')`: Layer Dense dengan 256 *neuron* dan fungsi aktivasi ReLU.
5. `tf.keras.layers.Dense(128, activation='relu')`: Layer Dense dengan 128 *neuron* dan fungsi aktivasi ReLU.
6. `tf.keras.layers.Dense(2, activation='softmax')`: Output layer dengan 2 *neuron* (sesuai dengan jumlah kelas) dan fungsi aktivasi *softmax* untuk klasifikasi multi-kelas.

Fungsi-fungsi yang digunakan dalam `model.compile()` yaitu:

1. `optimizer='adam'`: algoritma optimasi yang digunakan untuk menyesuaikan bobot (*weights*) dalam model. Adam adalah salah satu optimizernya.
2. `loss=tf.keras.losses.SparseCategoricalCrossentropy(from_logits=True)`: fungsi kerugian (loss function) yang digunakan untuk mengukur seberapa baik model memprediksi target yang benar. Dalam hal ini, menggunakan *Sparse Categorical Crossentropy*, yang cocok untuk kasus klasifikasi dengan label yang tidak terkode satu-hot.




Gambar 4. Arsitektur MobileNetV2.

6. Tahap Evaluasi Model

Dalam evaluasi model menggunakan *confusion matrix* adalah sebuah tabel yang sering digunakan untuk mengukur kinerja dari model klasifikasi. *Confusion matrix* adalah salah satu tools analitik prediktif yang menampilkan dan membandingkan nilai aktual atau nilai sebenarnya dengan nilai hasil prediksi model yang dapat digunakan untuk menghasilkan metrik evaluasi seperti accuracy, precision, recall, dan F1-Score [21].

3. HASIL DAN PEMBAHASAN

Hasil augmentasi citra pada proses akhir menghasilkan total 2.080 citra untuk setiap jenis kepiting, yaitu 1040 citra kepiting soka dan 1040 citra kepiting biasa. Hasil pembagian dataset yaitu 1664 data training, 208 data validasi, dan 208 data testing. Jumlah total sampel dalam dataset mencapai 2080, menciptakan struktur pembagian yang seimbang untuk melatih, memvalidasi, dan menguji kinerja model. Representasi visual dari citra-citra hasil augmentasi dapat dilihat pada Gambar 5. Gambar 6 menjelaskan proses yang menghasilkan dataset gambar baru dengan ukuran yang telah diubah sesuai dengan parameter yang diberikan (width dan height, 255 x 255).




Gambar 5. Hasil augmentasi kepiting tidak molting.



Gambar 6. Hasil resize dataset.


Dari hasil pelatihan model selama 15 epochs yang dapat dilihat pada Gambar 7, dapat disimpulkan bahwa model tersebut cukup baik. Grafik hasil pelatihan model memberikan gambaran yang positif terkait dengan kinerja model pada dataset training dan validasi. Pada akhir *epoch* ke-15, model berhasil mencapai *training loss* sebesar 0.00005, menunjukkan kemampuannya dalam meminimalkan kesalahan pada data training. Selain itu, akurasi training yang mencapai 100% menunjukkan tingkat akurasi yang tinggi dalam memprediksi label pada dataset *training*. Pada sisi validasi, model juga menunjukkan kinerja yang baik dengan mencapai *validation loss* sekitar 0.0006, menandakan kemampuannya untuk melakukan generalisasi pada data yang tidak digunakan selama pelatihan. *Validation accuracy* yang mencapai 100% mengindikasikan bahwa model dapat melakukan prediksi dengan akurat pada dataset baru yang tidak pernah dilihat sebelumnya. Grafik tersebut memberikan indikasi bahwa model tidak mengalami *overfitting*, yaitu kemampuannya untuk memberikan prediksi yang baik tidak hanya pada data pelatihan tetapi juga pada data baru. Oleh karena itu, hasil ini menunjukkan bahwa arsitektur MobileNetV2 yang digunakan dalam penelitian ini memiliki kemampuan yang baik dalam mengklasifikasikan gambar-gambar kepiting antara kepiting soka dan kepiting biasa setelah melalui proses pelatihan sebanyak 15 epoch. Dibandingkan dengan penelitian sebelumnya yang menggunakan algoritma machine learning seperti KNN dengan akurasi 98.33% [9], pendekatan MobileNetV2 ini memberikan kinerja lebih unggul dengan akurasi 100%. Hal ini menunjukkan bahwa arsitektur MobileNetV2 memiliki kelebihan dalam menangani gambar yang lebih kompleks dan variasi citra yang lebih luas.



Gambar 7. Grafik model akurasi (a), grafik model loss (b).

Evaluasi model merupakan langkah krusial untuk memahami sejauh mana performa suatu model. Model klasifikasi mencapai tingkat akurasi yang sangat tinggi sebesar 100%. Gambar 8 menjelaskan visualisasi confusion matrix menggambarkan kinerja model dengan sangat baik dalam memprediksi kelas. Dari total 100 sampel pada kelas kepiting biasa, model berhasil memprediksi semuanya dengan benar (*True*

Positives). Untuk kelas kepiting soka model juga mencapai performa luar biasa dengan memprediksi seluruh 108 sampel dengan benar (*True Positives*), tanpa satu pun sampel yang salah diprediksi sebagai kelas pertama (*False Negatives*). Dapat disimpulkan bahwa model memiliki kemampuan yang sangat baik dalam mengklasifikasikan kedua kelas dengan tingkat akurasi yang tinggi.



Gambar 8. Visualisasi Confusion Matrix.

4. PENUTUP

Penelitian ini berhasil menunjukkan bahwa arsitektur CNN *MobileNetV2* sangat efektif untuk mengklasifikasi *molting* dan tidak *molting* pada kepiting soka, dengan akurasi deteksi mencapai 100%. Model ini tidak hanya mampu mengklasifikasikan data *training* dengan baik, tetapi juga data baru yang tidak pernah dilihat sebelumnya, tanpa mengalami *overfitting*. Untuk pengembangan lebih lanjut, disarankan untuk menguji model ini pada skala dataset yang lebih besar serta mengaplikasikan pada sistem perangkat seluler untuk klasifikasi real-time pada budidaya kepiting soka.

UCAPAN TERIMA KASIH

Terimakasih kepada Prodi Teknik Informatika dan Fakultas Teknik Universitas Krisnadwipayana serta IPB *Fisheries and Marine Observation Station* (IFMOS) yang telah memberikan support dan perizinan dalam mendukung penelitian ini.

DAFTAR PUSTAKA

- [1] M. Z. U. Al Mamun et al., "Nutritional evaluation of edible swimming crabs *Portunus pelagicus* (Linnaeus, 1758) and *Portunus sanguinolentus* (Herbst, 1783) from coastal area of Bangladesh," *J. Agric. Food Res.*, vol. 15, p. 100972, Mar. 2024, doi: 10.1016/j.jafr.2024.100972.
- [2] I. Fajriaty, I. Fidrianny, N. F. Kurniati, N. M. Fauzi, S. H. Mustafa, and I. K. Adnyana, "In vitro and in silico studies of the potential cytotoxic, antioxidant, and HMG CoA reductase inhibitory effects of chitin from Indonesia mangrove crab (*Scylla serrata*) shells," *Saudi J. Biol. Sci.*, vol. 31, no. 5, p. 103964, May 2024, doi: 10.1016/j.sjbs.2024.103964.

- [3] X. Zi et al., "A molting chemical cue (*N*-acetylglucosamine-6-phosphate) contributes to cannibalism of Chinese mitten crab *Eriocheir sinensis*," *Aquat. Toxicol.*, vol. 263, p. 106666, Oct. 2023, doi: 10.1016/j.aquatox.2023.106666.
- [4] C. Agustiyana, Y. Hadiroseyani, I. Diatin, and I. Effendi, "Optimization of the production of soft shell crab (*Scylla sp.*) cultivation using the apartment system," *Egypt. J. Aquat. Res.*, Jul. 2024, doi: 10.1016/j.ejar.2024.05.003.
- [5] W. Herwanto, A. Khumaidi and H. P. Putro, "Feature Extraction and Classification of Tissue Mammograms Based on Grayscale and Gray Level Co-occurrence Matrix," 2021 International Seminar on Machine Learning, Optimization, and Data Science (ISMODE), Jakarta, Indonesia, 2022, pp. 131-134, doi: 10.1109/ISMODE53584.2022.9743131.
- [6] J. Mei, X. Liang, Y. Yu, Y. Lang, and X. Li, "The comparison and analysis of nutritional qualities of Chinese mitten crabs (*Eriocheir sinensis*) in rice field and pond culture modes," *Food Chem. X*, vol. 20, p. 100937, Dec. 2023, doi: 10.1016/j.fochx.2023.100937.
- [7] D. Zhang, W. Xu, F. Wang, J. He, and X. Chai, "Carbon dioxide fluxes from mariculture ponds with swimming crabs and shrimps in eastern China: The effect of adding razor clams," *Aquac. Reports*, vol. 22, p. 100917, Feb. 2022, doi: 10.1016/j.aqrep.2021.100917.
- [8] W. Ji, J. Peng, B. Xu, and T. Zhang, "Real-time detection of underwater river crab based on multi-scale pyramid fusion image enhancement and MobileCenterNet model," *Comput. Electron. Agric.*, vol. 204, p. 107522, Jan. 2023, doi: 10.1016/j.compag.2022.107522.
- [9] R. R. Baharuddin, M. Niswar, A. A. Ilham, and S. Kashihara, "Crab Molting Identification using Machine Learning Classifiers," in 2021 International Seminar on Machine Learning, Optimization, and Data Science (ISMODE), 2022, pp. 295–300, doi: 10.1109/ISMODE53584.2022.9743136.
- [10] C. Tang, G. Zhang, H. Hu, P. Wei, Z. Duan, and Y. Qian, "An improved YOLOv3 algorithm to detect molting in swimming crabs against a complex background," *Aquac. Eng.*, vol. 91, p. 102115, Nov. 2020, doi: 10.1016/j.aquaeng.2020.102115.
- [11] Z. Zhang, F. Liu, X. He, X. Wu, M. Xu, and S. Feng, "Soft-shell crab detection model based on YOLOF," *Aquac. Int.*, vol. 32, no. 4, pp. 5269–5298, Aug. 2024, doi: 10.1007/s10499-024-01426-2.
- [12] R. M. D. Cesar Ian A. Baluran, Edwin R. Arboleda, Marivic G. Dizon, "Crab Gender Classification Using Image Processing, Fuzzy Logic And K Nearest Neighbor (KNN) Classifier," *Int. J. Sci. Technol. Res.*, vol. 8, no. 10, pp. 1458–1462, 2019.
- [13] X. Chen, Y. Zhang, D. Li, and Q. Duan, "Chinese mitten crab detection and gender classification method based on GMNet-YOLOv4," *Comput. Electron. Agric.*, vol. 214, p. 108318, Nov. 2023, doi: 10.1016/j.compag.2023.108318.
- [14] J. Terven, D.-M. Córdova-Esparza, and J.-A. Romero-González, "A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS," *Mach. Learn. Knowl. Extr.*, vol. 5, no. 4, pp. 1680–1716, Nov. 2023, doi: 10.3390/make5040083.
- [15] J. Rogelio, E. Dadios, A. Bandala, R. R. Vicerra, and E. Sybingco, "Alignment control using visual servoing and mobilenet single-shot multi-box detection (SSD): a review," *Int. J. Adv. Intell. Informatics*, vol. 8, no. 1, p. 97, Mar. 2022, doi: 10.26555/ijain.v8i1.819.
- [16] H.-C. Chang, L.-W. Yu, B.-Y. Liu, and P.-C. Chang, "Classification of the implant-ridge relationship utilizing the MobileNet architecture," *J. Dent. Sci.*, vol. 19, no. 1, pp. 411–418, Jan. 2024, doi: 10.1016/j.jds.2023.08.002.
- [17] N. Shome, R. Kashyap, and R. H. Laskar, "Detection of tuberculosis using customized MobileNet and transfer learning from chest X-ray image," *Image Vis. Comput.*, vol. 147, p. 105063, Jul. 2024, doi: 10.1016/j.imavis.2024.105063.
- [18] I. Shafi, A. Mazahir, A. Fatima, and I. Ashraf, "Internal defects detection and classification in hollow cylindrical surfaces using single shot detection and MobileNet," *Measurement*, vol. 202, p. 111836, Oct. 2022, doi: 10.1016/j.measurement.2022.111836.
- [19] M. Xu, S. Yoon, A. Fuentes, and D. S. Park, "A Comprehensive Survey of Image Augmentation Techniques for Deep Learning," *Pattern Recognit.*, vol. 137, p. 109347, May 2023, doi: 10.1016/j.patcog.2023.109347.
- [20] F. J. M. Shamrat, S. Azam, A. Karim, K. Ahmed, F. M. Bui, and F. De Boer, "High-precision multiclass classification of lung disease through customized MobileNetV2 from chest X-ray images," *Comput. Biol. Med.*, vol. 155, p. 106646, Mar. 2023, doi: 10.1016/j.compbimed.2023.106646.
- [21] A. Khumaidi, Y. A. Purwanto, H. Sukoco, and S. H. Wijaya, "Using Fuzzy Logic to Increase Accuracy in Mango Maturity Index Classification: Approach for Developing a Portable Near-Infrared Spectroscopy Device," *Sensors*, vol. 22, no. 24, p. 9704, Dec. 2022, doi: 10.3390/s22249704.