

Klasifikasi Spesies Ikan Koi Berdasarkan Citra Menggunakan Metode YOLOv3-Tiny Dan OpenCV

Rauzi Saputra¹, Imam Muslem², Riyadhul Fajri³

^{1,3,2}Universitas Almuslim

ARTICLE INFO

Article history:

Received : 02 Maret 2026

Revised : 03 Maret 2026

Accepted : 03 Maret 2026

Keywords:

Koi Fish, Object Detection, YOLOv3-Tiny, Deep Learning, Computer Vision



This work is licensed under a [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/)

ABSTRACT

[Koi Fish Species Classification Based on Image Using YOLOv3-Tiny and OpenCV Methods] Identification of koi fish (*Cyprinus carpio*) varieties in aquaculture and ornamental fish industries is commonly performed manually through visual observation, making the process subjective, inconsistent, and inefficient, particularly at large production scales. This study aims to develop an automated image-based detection and classification system for koi varieties using the YOLOv3-Tiny algorithm integrated with OpenCV, capable of operating in real-time conditions. The dataset consists of 3,154 images of six koi varieties—Asagi, Bekko, Hikarimono, Kohaku, Sanke, and Showa—which were expanded to 6,360 images through data augmentation techniques. Image labeling and annotation were conducted using Roboflow, while model training was implemented with the Darknet framework in a Google Colab environment supported by GPU acceleration. System performance was evaluated using mean Average Precision (mAP), loss function analysis, and both static image and real-time video testing. Experimental results demonstrate that the YOLOv3-Tiny model is capable of accurately detecting and classifying koi varieties with stable inference speed suitable for real-time applications. The proposed system enhances objectivity, consistency, and efficiency in koi variety identification and shows strong potential for practical implementation in technology-driven ornamental fish farming and trading industries.

ABSTRAK

Identifikasi varietas ikan koi (*Cyprinus carpio*) dalam industri budidaya dan perdagangan ikan hias umumnya masih dilakukan secara manual berdasarkan pengamatan visual, sehingga rentan terhadap subjektivitas, inkonsistensi, dan kurang efisien pada skala besar. Penelitian ini bertujuan mengembangkan sistem deteksi dan klasifikasi varietas ikan koi berbasis pengolahan citra menggunakan algoritma YOLOv3-Tiny dan OpenCV yang mampu bekerja secara real-time. Dataset yang digunakan terdiri dari 3.154 citra enam varietas koi, yaitu Asagi, Bekko, Hikarimono, Kohaku, Sanke, dan Showa, yang kemudian ditingkatkan menjadi 6.360 citra melalui proses augmentasi data. Pelabelan dilakukan menggunakan Roboflow dan pelatihan model menggunakan framework Darknet pada lingkungan Google Colab dengan dukungan GPU. Evaluasi kinerja sistem dilakukan menggunakan metrik *mean Average Precision* (mAP), analisis *loss function*, serta pengujian pada citra statis dan video real time. Hasil penelitian menunjukkan bahwa model YOLOv3-

Kata kunci:

Ikan Koi, Deteksi Objek, YOLOv3-Tiny, Deep Learning, Computer Vision.

Corresponding Author:

Rauzi Saputra

Universitas Almuslim

Email: rauzaicity@gmail.com

Tiny mampu mendeteksi dan mengklasifikasikan varietas ikan koi dengan akurasi yang baik serta kecepatan inferensi yang stabil untuk aplikasi real time. Sistem yang dikembangkan dapat meningkatkan objektivitas, konsistensi, dan efisiensi dalam proses identifikasi varietas koi, serta berpotensi diterapkan dalam mendukung industri budidaya dan perdagangan ikan hias berbasis teknologi kecerdasan buatan.

PENDAHULUAN

Ikan koi (*Cyprinus carpio*) merupakan salah satu komoditas ikan hias yang memiliki nilai estetika dan ekonomi tinggi. Keunikan warna serta variasi pola tubuh menjadikan ikan ini banyak diminati sebagai hiasan sekaligus memiliki prospek bisnis yang menjanjikan. Seiring berkembangnya teknik budidaya dan inovasi pembentukan varietas warna baru, muncul tantangan dalam proses identifikasi jenis ikan koi, khususnya bagi pemula yang belum memiliki pengalaman dalam membedakan karakteristik tiap varietas. Oleh karena itu, diperlukan suatu sistem klasifikasi otomatis untuk membantu proses identifikasi jenis ikan koi secara lebih objektif dan efisien [1], [2]. Selain itu, kombinasi warna dan pola tubuh yang khas menjadi dasar klasifikasi varietas seperti Kohaku, Sanke, dan Showa yang telah distandardisasi dalam praktik budidaya modern [3].

Indonesia memiliki potensi besar dalam pengembangan industri ikan koi karena didukung oleh iklim tropis, ketersediaan sumber daya air, dan keanekaragaman hayati yang melimpah. Beberapa daerah seperti Blitar, Kediri, dan Sukabumi telah berkembang menjadi sentra produksi ikan koi yang mampu memenuhi kebutuhan pasar domestik maupun ekspor. Data dari Kementerian Kelautan dan Perikanan menunjukkan adanya peningkatan produksi serta nilai ekspor ikan hias dalam beberapa tahun terakhir [4]. Sejalan dengan itu, Badan Pusat Statistik juga mencatat pertumbuhan positif ekspor perikanan Indonesia, baik dari sisi volume maupun nilai ekonomi [5]. Hal ini menunjukkan bahwa Indonesia memiliki peluang strategis untuk memperkuat posisinya sebagai produsen ikan koi di pasar global.

Meskipun memiliki potensi yang besar, proses identifikasi dan seleksi ikan koi di lapangan masih dilakukan secara manual dan sangat bergantung pada subjektivitas peternak. Penilaian visual manusia berpotensi menimbulkan inkonsistensi, memerlukan waktu yang relatif lama, serta rentan terhadap kelelahan pengamat [6]. Pada skala industri yang menuntut kecepatan dan ketepatan, metode manual dinilai kurang efisien dan berisiko menyebabkan kesalahan klasifikasi kualitas [7], [8], [9], [10].

Perkembangan teknologi kecerdasan buatan menawarkan solusi melalui pendekatan pengolahan citra digital. Pendekatan ini memungkinkan analisis karakteristik visual objek dilakukan secara otomatis dan objektif, serta telah banyak diterapkan dalam bidang akuakultur untuk identifikasi spesies dan pengukuran biometrik [11]. Salah satu algoritma yang efektif dalam sistem deteksi objek adalah YOLO (*You Only Look Once*), yang mampu melakukan deteksi secara real-time melalui satu kali proses inferensi [12]. Varian YOLOv3-Tiny dikembangkan sebagai versi ringan dengan ukuran model yang lebih kecil sehingga sesuai untuk implementasi pada perangkat dengan spesifikasi terbatas, namun tetap mempertahankan tingkat akurasi yang memadai [13]. Dalam implementasinya, algoritma ini sering dikombinasikan dengan pustaka OpenCV untuk mendukung proses pra-pemrosesan citra dan pengembangan sistem visi komputer yang andal [14].

Selain metode deteksi objek, penelitian dalam bidang klasifikasi citra juga menunjukkan bahwa pendekatan deep learning berbasis Convolutional Neural Network (CNN) memiliki performa yang sangat baik dalam mengenali pola visual kompleks. Studi oleh Luthfi et al. menunjukkan bahwa model CNN seperti ResNet50 dan VGG16 mampu menghasilkan tingkat akurasi tinggi dalam klasifikasi tingkat kematangan objek berbasis citra, sehingga membuktikan efektivitas pendekatan deep learning dalam pengolahan citra digital dan pengenalan pola visual [15]. Temuan tersebut memperkuat relevansi penggunaan pendekatan deep learning dalam pengembangan sistem klasifikasi ikan koi berbasis citra.

Berdasarkan uraian tersebut, penelitian ini difokuskan pada pengembangan sistem pendeteksi dan pengklasifikasi corak warna ikan koi berbasis algoritma YOLOv3-Tiny. Sistem yang dikembangkan diharapkan mampu meningkatkan objektivitas, konsistensi, dan efisiensi dalam proses identifikasi ikan koi, serta mendukung penguatan industri budidaya dan perdagangan ikan hias di Indonesia melalui pemanfaatan teknologi kecerdasan buatan.

METODE

Penelitian ini menggunakan pendekatan eksperimental komputasional yang berfokus pada pengembangan model deteksi objek berbasis *deep learning*. Sistem dieksekusi menggunakan bahasa pemrograman Python versi 3.9 dan *framework* Darknet yang terintegrasi di dalam lingkungan *cloud computing* Google Colaboratory (Google Colab). Pemanfaatan Google Colab dipilih untuk mengeksploitasi akselerasi *Graphics Processing Unit* (GPU) tipe NVIDIA Tesla secara dinamis, sehingga proses pelatihan iteratif jaringan saraf tiruan dapat berlangsung lebih cepat tanpa harus terbebani oleh batasan spesifikasi perangkat keras lokal. Secara arsitektural, alur sistem bermula dari tahap pra-pemrosesan di mana citra masukan diseragamkan resolusinya menjadi 416x416 piksel, lalu diumpankan ke dalam model YOLOv3-Tiny guna mengekstraksi fitur visual corak warna, dan diakhiri dengan keluaran berupa *bounding box* yang memuat probabilitas keyakinan (*confidence score*) untuk tiap kelas varietas.

Tahapan pengumpulan dan perancangan data (*dataset*) merupakan langkah esensial untuk menjamin kinerja model. Citra ikan koi dikumpulkan dari dokumentasi mandiri, repositori daring, serta komunitas pecinta koi, yang menghasilkan total 3.154 gambar mentah untuk enam varietas utama. Distribusi awal dataset mentah ini dapat dilihat secara rinci pada Tabel 1.

Tabel 1. Distribusi jumlah citra mentah

Varietas Koi	Jumlah Citra Mentah	Persentase
Showa	720	22,83%
Kohaku	622	19,72%
Bekko	617	19,56%
Hikarimono	547	17,34%
Asagi	347	11,00%
Sanke	301	9,54%
Total	3.154	100,00%

Berdasarkan data pada Tabel 1, terdapat ketimpangan jumlah sampel (*class imbalance*) yang signifikan antar kelas, dengan kelas Showa sebagai mayoritas dan kelas Sanke sebagai minoritas ekstrem. Untuk mengatasi masalah tersebut dan mencegah model menjadi bias, diterapkan teknik augmentasi data melalui platform Roboflow yang difokuskan pada peningkatan jumlah sampel untuk kelas minoritas. Teknik yang diterapkan meliputi rotasi acak (*random rotation*), pembalikan horizontal (*horizontal flip*), serta penyesuaian tingkat kecerahan dan saturasi. Hasil akhir penyeimbangan dataset setelah melalui proses augmentasi dapat dilihat pada Tabel 2.

Tabel 2. Distribusi dataset setelah proses augmentasi

Varietas Koi	Jumlah Citra	Persentase
Showa	1.060	16,67%
Kohaku	1.060	16,67%
Bekko	1.060	16,67%
Hikarimono	1.060	16,67%
Asagi	1.060	16,67%
Sanke	1.060	16,67%
Total	6.360	100,00%


Tabel 2 menunjukkan bahwa setiap varietas kini memiliki representasi data yang merata dengan total akhir sebanyak 6.360 citra. Dataset yang telah seimbang ini selanjutnya didistribusikan secara proporsional menjadi tiga bagian, yaitu 88% sebagai data latih (5.565 citra), 8% sebagai data validasi (530 citra), dan 4% sebagai data uji (265 citra).

Pada fase konfigurasi algoritma dan pelatihan model, modifikasi struktural diterapkan secara langsung pada berkas arsitektur *yolov3-tiny_obj.cfg*. Parameter lapisan disesuaikan untuk mengenali spesifik enam varietas koi, yakni dengan mengubah parameter *classes* menjadi 6 pada lapisan klasifikasi. Perubahan ini mengharuskan penyesuaian jumlah filter konvolusional pada lapisan sebelumnya menggunakan formulasi matematika $Filters = (Classes + 5) \times 3$, yang menghasilkan parameter 33 filter $Filters = (Classes + 5) \times 3$. Pengaturan *hyperparameter* pelatihan ditetapkan dengan ukuran *batch* 64, tingkat pembelajaran (*learning rate*) 0,01, dan total iterasi maksimal (*max batches*) sebesar 12.000 iterasi. Untuk mempercepat konvergensi jaringan, proses pelatihan memanfaatkan teknik *transfer learning*

dengan menginisialisasi bobot pralatih (*pre-trained weights*) dari berkas *yolov3-tiny.conv.15*. Kinerja akhir sistem kemudian diukur melalui metrik *Intersection over Union* (IoU) dengan ambang batas 0,5, nilai Presisi, nilai *Recall*, serta akumulasi kalkulasi akurasi keseluruhan melalui skor *mean Average Precision* (mAP).

HASIL DAN PEMBAHASAN

Tahap pertama dalam evaluasi kinerja model adalah menganalisis metrik fungsi kerugian (*Average Loss*) yang terekam selama proses pelatihan algoritma YOLOv3-Tiny hingga mencapai iterasi maksimum 12.000. Perbandingan grafik konvergensi pada Gambar 1 menunjukkan perbedaan tingkat pembelajaran yang signifikan antara model yang dilatih dengan dataset mentah dan model dengan dataset teraugmentasi. Pada model sebelum augmentasi, proses konvergensi kurang maksimal dengan nilai akhir *average loss* yang tertahan pada angka 12.400. Sebaliknya, pelatihan pada model sesudah augmentasi memperlihatkan kurva *loss* yang mengalami penurunan jauh lebih tajam dan stabil, khususnya saat memasuki rentang 5.000 hingga 8.000 iterasi. Pada iterasi akhir, model berhasil mencapai titik konvergensi optimal dengan menekan nilai *average loss* hingga menyentuh angka 10.662. Penurunan nilai kerugian ini membuktikan secara empiris bahwa penambahan variasi data sintesis (rotasi, penyesuaian kecerahan, dan saturasi) sangat esensial dalam membantu jaringan saraf membedakan fitur kompleks corak ikan koi, sekaligus mencegah terjadinya *overfitting*.



Gambar 1. Grafik perbandingan penurunan *Average Loss* sebelum augmentasi (kiri) dan sesudah augmentasi (kanan)


Pengujian akurasi deteksi secara kuantitatif dilakukan pada data uji (*Test Set*) menggunakan metrik *Intersection over Union* (IoU) dengan ambang batas 0,5. Kinerja keseluruhan model dibuktikan dengan capaian nilai *mean Average Precision* (mAP) akhir sebesar 84,86%. Capaian ini secara langsung menjawab rumusan masalah dan menunjukkan efektivitas dari penerapan teknik pra-pemrosesan data. Seperti yang ditunjukkan pada Tabel 3, model yang dilatih menggunakan data teraugmentasi (6.360 citra) mengalami peningkatan akurasi sebesar 4,74% dibandingkan dengan model yang dilatih hanya menggunakan dataset mentah (3.154 citra). Peningkatan signifikan ini terjadi karena model menjadi lebih adaptif terhadap berbagai gangguan visual yang sering ditemui pada objek di bawah air, seperti pantulan cahaya (*glare*) dan kondisi air yang tidak jernih.

Tabel 3. Perbandingan performa model sebelum dan sesudah augmentasi

Kondisi Data	Jumlah Dataset	Nilai mAP (%)
Sebelum Augmentasi	3.154 citra	80,12%
Sesudah Augmentasi	6.360 citra	84,86%
Peningkatan	+3.711 citra	4,74%


Analisis performa mendetail untuk setiap kelas varietas ikan koi dievaluasi berdasarkan metrik *Average Precision* (AP), yang disajikan pada Gambar 2. Kelas Hikarimono dan Showa mencatatkan nilai AP tertinggi, berturut-turut sebesar 88,62% dan 87,45%. Tingginya akurasi pada kedua kelas ini sangat dipengaruhi oleh karakteristik visual yang tegas; Hikarimono memiliki sisik metalik, sedangkan Showa didominasi oleh warna dasar hitam pekat. Sebaliknya, kelas Asagi (72,80%) dan Sanke (78,10%)

mencatatkan akurasi terendah. Hal ini disebabkan corak jaring biru pada Asagi yang sering kali berbau dengan warna air kolam, sementara pola bercak hitam (*Sumi*) pada Sanke sangat mirip dengan varietas Showa, sehingga memicu kebingungan model dalam proses klasifikasi. Meskipun demikian, penambahan data sintesis pada varietas minoritas ini telah berhasil membuat model tetap memberikan hasil klasifikasi yang sangat kompetitif.



Gambar 2. Hasil Average Precision (AP) untuk setiap kelas varietas koi

Evaluasi secara kualitatif (*inference*) dilakukan dengan menjalankan model pada aliran video dan citra uji. Hasil visualisasi pada Gambar 3 menunjukkan bahwa arsitektur YOLOv3-Tiny yang diintegrasikan dengan OpenCV mampu menghasilkan *bounding box* yang ketat dan presisi (*High IoU*). Model sukses mendeteksi dan melabeli objek secara benar (*True Positive*) dengan tingkat probabilitas (*confidence score*) rata-rata di atas 80% pada kondisi yang ideal. Penggunaan arsitektur ringan (*Tiny*) ini sejalan dengan penelitian sebelumnya yang menunjukkan keunggulan YOLO dalam mempertahankan kecepatan inferensi (*Frames Per Second*) tinggi pada perangkat lokal. Hasil ini membuktikan bahwa metode yang diusulkan jauh lebih seimbang secara komputasi dibandingkan arsitektur CNN berat seperti ResNet18, sekaligus mengeliminasi inkonsistensi penilaian subjektif pada metode manual.



Gambar 3. Contoh visualisasi True Positive pada varietas Kohaku (kiri) dan False Positive pada deteksi bayangan batu (kanan)

Walaupun sistem menunjukkan akurasi yang tinggi, analisis kesalahan (*error analysis*) juga menemukan beberapa batasan. Berdasarkan Gambar 3 (kanan), kesalahan *False Positive* (FP) masih muncul ketika model keliru mendeteksi batu, lumut, atau pantulan cahaya matahari sebagai ikan koi akibat latar belakang kolam yang terlalu ramai (*cluttered background*). Selain itu, anomali *False Negative* (FN) terjadi saat objek gagal dideteksi karena faktor oklusi (ikan yang berenang tumpang tindih). Kesalahan *Misclassification* juga tercatat pada ikan varietas Sanke yang dilabeli sebagai Showa akibat kemiripan struktur geometris pola warna. Temuan-temuan ini menjadi justifikasi penting bahwa meskipun akurasi mAP sudah mencapai 84,86%, kompleksitas lingkungan bawah air tetap menjadi tantangan komputasi utama bagi model *deep learning one-stage detector* varian ringan

KESIMPULAN

Berdasarkan hasil penelitian dan pengujian yang telah dilakukan, dapat disimpulkan bahwa algoritma YOLOv3-Tiny yang diintegrasikan dengan pustaka OpenCV terbukti sangat efektif dalam mendeteksi dan mengklasifikasikan enam varietas ikan koi secara otomatis. Model kecerdasan buatan

yang dikembangkan berhasil mencapai tingkat akurasi yang tinggi dengan capaian nilai *mean Average Precision* (mAP) akhir sebesar 84,86%. Capaian optimal ini sangat dipengaruhi oleh penerapan teknik augmentasi data pada fase pra-pemrosesan, yang sukses mengatasi masalah ketimpangan kelas dan mampu mendongkrak performa akurasi model sebesar 4,74% dibandingkan penggunaan dataset mentah. Secara arsitektural, penggunaan YOLOv3-Tiny memberikan keseimbangan yang sangat baik antara kecepatan komputasi dan presisi, sehingga memungkinkan sistem deteksi untuk beroperasi secara real time dan efisien meskipun dijalankan pada perangkat keras dengan sumber daya komputasi terbatas.

Secara keseluruhan, sistem yang diusulkan ini memberikan solusi praktis dan objektif untuk menggantikan metode identifikasi manual yang rentan terhadap subjektivitas pengamat, sehingga sangat berpotensi untuk diimplementasikan guna mendukung otomatisasi pada industri budidaya ikan hias. Meskipun demikian, model masih memiliki keterbatasan berupa munculnya deteksi keliru (*False Positive*) akibat latar belakang kolam yang terlalu ramai serta kegagalan deteksi (*False Negative*) akibat oklusi saat ikan saling menutupi. Oleh karena itu, penelitian selanjutnya disarankan untuk memperkaya variasi dataset pada kondisi pencahayaan ekstrem dan mengeksplorasi penggunaan arsitektur YOLO yang lebih mutakhir (seperti YOLOv8 atau YOLOv10) untuk menekan tingkat kesalahan klasifikasi. Sebagai tambahan pada aspek perangkat keras, integrasi filter optik *Circular Polarizer* (CPL) pada lensa kamera sangat direkomendasikan guna mereduksi silau pantulan permukaan air sebelum citra diproses oleh algoritma.

DAFTAR PUSTAKA

- [1] G. M. Aqshal and D. D. Hutagalung, "Klasifikasi Jenis Ikan Koi Menggunakan Ekstraksi Warna HSV dan Metode Adaptive Neuro-Fuzzy Inference System (ANFIS)," *Jurnal ICT: Information Communication & Technology*, vol. 23, no. 2, pp. 1–8, 2023, doi: 10.36054/jict-ikmi.v23i2.172.
- [2] I. R. Muslem and T. M. Johan, "KLIK: Kajian Ilmiah Informatika dan Komputer Klasifikasi Citra Ikan Menggunakan Algoritma Convolutional Neural Network dengan Arsitektur VGG-16," *Media Online*, vol. 4, no. 2, pp. 978–985, 2023, doi: 10.30865/klik.v4i2.1209.
- [3] I. A. Iswanto and S. H. Almukhlis, "Automatic Koi Grading System using Image Processing and Support Vector Machine," in *2020 International Conference on Computer Engineering, Network, and Intelligent Multimedia (CENIM)*, 2020, pp. 107–111. doi: 10.1109/CENIM51130.2020.9297943.
- [4] KKP, "KKP Ajak Para Breeder Hasilkan Ikan Koi Kualitas Ekspor. Website." [Online]. Available: <https://ppid.kkp.go.id/upp/direktorat-jenderal-perikanan-budi-daya/news/detail/kkp-ajak-para-breeder-hasilkan-ikan-koi-kualitas-ekspor/>
- [5] BPS, "Statistik Ekspor Ikan Hias Indonesia. Website,," Jakarta, 2025.
- [6] A. L. Syafei, A. Sajiah, and T. W. Purboyo, "Koi Fish Detection and Classification System using YOLO Algorithm," *International Journal of Applied Engineering Research*, vol. 17, no. 1, pp. 55–61, 2022.
- [7] J. Zhao, S. Zhang, J. Liu, and H. Wang, "Application of Deep Learning in Fish Classification and Breeding: A Review," *Aquaculture*, vol. 535, p. 736356, 2021, doi: 10.1016/j.aquaculture.2021.736356.
- [8] D. Armiaady and I. M. R, "Klasifikasi Kualitas Buah Pisang Berdasarkan Citra Buah Menggunakan Stochastic Gradient Descent," *KLIK: Kajian Ilmiah Informatika dan Komputer*, vol. 4, no. 2, 2023.
- [9] C. H. H. Jannah, I. Muslem, and D. Azmi, "Jurnal Ilmu Komputer Aceh Klasifikasi Plat Nomor Kendaraan Berdasarkan Wilayah Tertentu Menggunakan Algoritma Optical Character Recognition," *Jurnal Ilmu Komputer Aceh*, Oct. 2025, [Online]. Available: <https://jurnal.fikompublisher.com/ilka/article/view/16>
- [10] I. Muslem, I. Irvanizam, A. Almuzammil, and F. Johar, "Adaptive Heuristic-Based Ant Colony Optimization for Multi-Constraint University Course Timetabling with Morning Slot Preference for Energy Efficiency," *Jurnal Teknik Informatika (Jutif)*, vol. 6, no. 6, pp. 5930–5943, Jan. 2026, doi: 10.52436/1.jutif.2025.6.6.5588.
- [11] X. Yang, S. Zhang, J. Liu, Q. Gao, S. Dong, and C. Zhou, "Deep learning for smart fish farming: applications, opportunities and challenges," *Reviews in Aquaculture*, vol. 13, no. 1, pp. 66–90, 2021, doi: 10.1111/raq.12462.
- [12] I. V. S. L. Haritha, M. Harshini, S. Patil, and J. Philip, "Real Time Object Detection using YOLO Algorithm," in *2022 6th International Conference on Electronics, Communication and Aerospace Technology*, 2022, pp. 1465–1468. doi: 10.1109/ICECA55336.2022.10009184.

- [13] Z. Jiang, L. Zhao, S. Li, and Y. Jia, "Real-time object detection method based on improved YOLOv3-tiny," *IEEE Access*, vol. 8, pp. 184535–184545, 2020, doi: 10.1109/ACCESS.2020.3030217.
- [14] K. M. Knausgård, N. Wiker, and T. Andersen, "Temperate Fish Detection and Classification: a Deep Learning based Approach," *Applied Intelligence*, vol. 52, pp. 6988–7001, 2022, doi: 10.1007/s10489-020-02154-9.
- [15] L. Luthfi, R. I. Muslem, D. Armiady, S. Sriwinar, R. Fajri, and I. Iqbal, "Analysis of CNN Method for Image Classification of Coconut Ripeness Levels," in *2023 Eighth International Conference on Informatics and Computing (ICIC)*, 2023, pp. 1–6. doi: 10.1109/ICIC60109.2023.10381964.