

Deteksi Ikan Lele (*Clarias sp*) di Luar Kolam Berbasis AI YOLOv9 untuk Mitigasi Kehilangan Hasil Ternak

Anak Agung Gede Oka Kessawa Adnyana^{1*}, Ni Wayan Jeri Kusuma Dewi², I Nyoman Darma Kotama³

^{1,2} Institut Bisnis dan Teknologi Indonesia, Denpasar, Indonesia

³ Graduate School of Environmental, Life, Natural Science and Technology, Okayama University, Japan

¹kessawa@instiki.ac.id*, ²wayan.kusumadewi@instiki.ac.id, ³dkotama@s.okayama-u.ac.jp

INFO ARTIKEL

Article history:

Received Juni 2025

Accepted Juli 2025

Published Juli 2025

ABSTRAK

Budidaya ikan lele (*Clarias sp*) di Indonesia merupakan salah satu komoditas yang memiliki nilai tinggi, juga memiliki berbagai tantangan. Salah satu tantangan tersebut adalah berkurangnya jumlah panen karena adanya ikan yang tercecer atau keluar dari kolam akibat desain kolam yang kurang optimal atau saat proses panen dan sortir. Ikan yang keluar dari kolam berisiko mati karena kekurangan oksigen, menyebabkan penurunan hasil panen. Penelitian ini bertujuan mengembangkan sistem deteksi objek berbasis kecerdasan buatan (AI) menggunakan model YOLOv9 untuk mendeteksi ikan lele yang tercecer di luar kolam secara real-time. Dataset terdiri dari 158 gambar hasil augmentasi dari 66 gambar asli yang dikumpulkan di peternakan lele di Klungkung, Bali. Dataset dibagi ke dalam 88% pelatihan, 8% validasi, dan 4% pengujian. Dua varian model diuji: YOLOv9-c dan YOLOv9-e, masing-masing dilatih dalam 5, 25, dan 50 epoch. Evaluasi dilakukan menggunakan metrik precision, recall, F1-score, dan confusion matrix. Hasil menunjukkan bahwa YOLOv9-c pada 50 epoch memberikan performa terbaik dengan F1-score tertinggi, meskipun YOLOv9-e menunjukkan akurasi deteksi yang kompetitif. Penelitian ini membuktikan potensi penggunaan YOLOv9 sebagai solusi cerdas dalam mitigasi kehilangan hasil panen ikan lele.

Kata Kunci: Object Detection; Lele; YOLO, Computer Vision, GELAN

ABSTRAK

Catfish farming in Indonesia is one of the high-value aquaculture commodities, but it also faces several challenges. One of the key challenges is the reduction in harvest yield due to fish escaping or being displaced from the pond, often caused by suboptimal pond design or during harvesting and sorting processes. Fish that leave the pond are at risk of mortality due to oxygen deprivation, leading to decreased overall yield. This study aims to develop an object detection system based on artificial intelligence (AI) using the YOLOv9 model to detect catfish that have escaped outside the pond in real time. The dataset comprises 158 augmented images derived from 66 original photos collected at a catfish farm in Klungkung, Bali. The dataset was divided into 88% for training, 8% for validation, and 4% for testing. Two model variants were evaluated: YOLOv9-c and YOLOv9-e, each trained for 5, 25, and 50 epochs. Evaluation metrics included precision, recall, F1-score, and confusion matrix. The results show that YOLOv9-c trained for 50 epochs achieved the highest F1-score, although YOLOv9-e also demonstrated competitive detection accuracy. This research highlights the potential of YOLOv9 as an intelligent solution for mitigating post-harvest losses in catfish aquaculture.

Keywords: Object Detection; Catfish; YOLO, Computer Vision, GELAN

©2025 Authors. Licensed Under [CC-BY-NC-SA 4.0](#)

1. Pendahuluan

Sebagai salah satu komoditas air tawar di Indonesia, ikan lele khususnya spesies *Clarias sp* memiliki permintaan yang tinggi di pasar Indonesia karena nilai protein yang tinggi namun mudah untuk dibudidayakan (Indonesia, n.d.). Walaupun tergolong mudah, budidaya ikan lele sendiri memiliki beberapa tantangan, seperti pentingnya menjaga kondisi air (Hidayati et al., 2021), munculnya parasit ikan (Hastuti & Herlina, 2020), dan faktor lainnya yang menyebabkan lingkungan hidup ikan menjadi tidak nyaman serta didukung oleh desain kolam yang kurang optimal seperti ukuran tinggi dinding yang kurang memadai dapat menyebabkan ikan melompat keluar dari kolam.

Resiko ikan yang tercecer di luar kolam juga bisa terjadi ketika proses sorting dan pada saat proses panen. Ikan yang berada di luar kolam berisiko mati akibat terluka, dehidrasi hingga kekurangan oksigen. Hal ini akan mengurangi jumlah hasil panen dan mengakibatkan kerugian bagi peternak. Oleh karena itu, diperlukan solusi inovatif untuk mendeteksi dan menangani ikan yang keluar dari kolam secara cepat dan efisien.

Seiring dengan perkembangan teknologi, penerapan kecerdasan buatan atau artificial intelligence (AI) telah diterapkan dalam berbagai aspek kehidupan masyarakat. Computer vision sebagai salah satu bidang keilmuan dari AI telah diterapkan dalam berbagai hal, terutama dengan kegiatan perikanan, salah satunya adalah model deteksi ikan yang diterapkan pada smart aquaculture oleh Rosales et al menggunakan metode Faster R-CNN yang mampu melakukan deteksi ikan dengan presisi yang tinggi (Rosales et al., 2021). Proses segmentasi dan klasifikasi ikan juga sudah dilakukan menggunakan metode Hybrid transformer-CNN yang dapat memberikan hasil segmentasi yang tepat dan akurat (Kumar & Shukla, 2025).

Pendekatan yang digunakan dalam penelitian ini menggunakan metode You Only Look Once (YOLO), yang merupakan sebuah model yang berjalan di atas MS-COCO, dikenal memiliki kemampuan dalam melakukan deteksi secara real-time dengan akurasi tinggi (Wang et al., 2022). Model terbaru dalam keluarga YOLO, yaitu YOLOv9 yang berbasis pada arsitektur neural network yang disebut dengan Generalized Efficient Layer Aggregation Network (GELAN) menghadirkan peningkatan yang signifikan untuk proses deteksi model yang berukuran ringan hingga model yang berukuran besar (Wang et al., 2024). Metode YOLOv9 memiliki predecessor yang juga telah teruji, seperti yang dirangkum oleh Gheorghe et al mengenai metode YOLO yang diterapkan pada dunia otomotif, seperti lalu lintas dan manufaktur (Gheorghe et al., 2024). Metode YOLO juga telah digunakan pada bidang infrastruktur dan bangunan untuk mendeteksi berbagai jenis kerusakan dengan hasil yang klasifikasi yang presisi (Adnyana et al., 2024; Di et al., 2023; Jeong, 2020; Wu et al., 2023).

Pada bidang akuakultur, metode YOLO juga sudah diuji untuk melakukan deteksi ikan pada lingkungan yang padat menggunakan YOLOv5 (Li et al., 2022) dan juga melakukan deteksi pada lingkungan bawah air (Muksit et al., 2022).


Dalam penelitian ini, peneliti akan membangun sebuah dataset khusus yang berisi citra ikan lele yang tercecer di luar kolam. Dataset ini akan digunakan untuk melatih model YOLOv9, dengan tujuan menghasilkan bobot deteksi yang akurat dan efisien. Model yang dihasilkan diharapkan mampu mendeteksi secara real-time keberadaan ikan di luar kolam, sehingga dapat digunakan sebagai bagian dari sistem pemantauan berbasis kecerdasan buatan (AI) untuk memperingatkan jika terjadi kebocoran atau pelarian ikan. Penelitian ini diharapkan dapat membantu peternak dalam mencegah kerugian dengan menyelamatkan ikan secara lebih cepat dan tepat.

2. Metode Penelitian

Penelitian ini dilakukan dengan melalui 4 tahapan, yang terdiri dari tahapan pengumpulan data, tahapan persiapan data latih, tahapan pelatihan model, dan tahapan evaluasi.

2.1 Pengumpulan Data

Proses penelitian dimulai dengan tahapan pengumpulan dataset yang dilakukan dengan mengunjungi peternakan lele pondok mina santi yang berlokasi di kabupaten klungkung. Dataset dikumpulkan dengan melakukan simulasi, jika terdapat lele yang tercecer di lingkungan kolam. Proses pengumpulan dataset berhasil memperoleh 66 buah gambar yang berisikan objek lele yang berada di luar kolam.




Gambar 1. Proses notasi gambar

Sumber: Penulis, 2025

2.2 Persiapan Data latih

Proses penelitian akan dilanjutkan ke tahapan persiapan data latih, yang terdiri dari preprocessing dan augmentasi data. Proses ini bertujuan untuk mempersiapkan dataset agar format data sesuai dengan kebutuhan proses pelatihan data. Proses preprocessing diawali dengan penotasian data menggunakan tools roboflow yang bertujuan untuk menandai objek dengan label yang sesuai dengan objek yang ingin dideteksi. proses dilanjutkan dengan melakukan auto-orient dan resize gambar ke ukuran 640x640 pixel. Proses augmentasi terdiri dari pengaturan brightness ke $\pm 15\%$ dan pengaturan rotasi $\pm 10^\circ$ yang bertujuan untuk meningkatkan jumlah dataset. sehingga dengan augmentasi ini, total dataset berjumlah 158 gambar. Dataset kemudian dikumpulkan menjadi 3 kelompok, yaitu 88% untuk pelatihan, 8% untuk validasi, dan 4% untuk pengujian.



Gambar 2. Pembagian kelompok dataset

2.3 Pelatihan Model dan Evaluasi

Tahapan selanjutnya adalah melakukan pelatihan pada model YOLOv9. 2 sub jenis dari model YOLOv9 adalah YOLOv9-c dan YOLOv9-e. YOLOv9-c adalah bentuk model yang bersifat umum dengan menekankan ukurannya yang lebih ringan dibandingkan YOLOv7 AF. YOLOv9-c memiliki 42 % lebih sedikit parameter dan 22 % lebih sedikit FLOPs dibandingkan YOLOv7 AF, namun

mencapai AP $\approx 53\%$ (Wang et al., 2024). YOLOv9-e adalah model yang bertujuan untuk menangani deteksi objek yang lebih detail. YOLOv9-e memiliki 16 % lebih sedikit parameter, 27 % lebih sedikit FLOPs, dan mengungguli YOLOv8-X dengan +1.7 % mAP@0.5 (72,8% dibandingkan dengan 71.1%). Training akan dilakukan pada YOLOv9-c dan YOLOv9-e untuk mengetahui perbedaan dari kedua model tersebut. Proses training dimulai dengan clone dataset dari roboflow. Tahapan training kemudian kedua submodel dimulai dengan 5 epoch yang dilanjutkan dengan 25, dan 50 epoch.

```
10 !python train.py \
11 --batch 16 --epochs 25 --img 640 --device 0 --min-items 0 --close-mosaic 15 \
12 --data {dataset.location}/data.yaml \
13 --weights {HOME}/weights/yolov9-c.pt \
14 --cfg models/detect/yolov9-c.yaml \
15 --hyp hyp.scratch-high.yaml]
```

Gambar 3. Command training model

Sumber: Penulis, 2025

metrik yang digunakan untuk mengukur penelitian ini adalah nilai precision, nilai recall, nilai F1 serta confusion matrix dari masing-masing trained weight. pengukuran menggunakan metric ini mampu mengukur tingkat confidence sebuah model secara sensitif tugas dari model tersebut. Komponen metrik ini terdiri dari seberapa tinggi tingkat keberhasilan model dalam mendeteksi objek target atau seberapa besar tingkat kegagalan model dalam mendeteksi objek (Yacouby & Axman, 2020). Terdapat 4 komponen penilaian yang terlibat dalam metrik ini yang merupakan pasangan keterangan terhadap hasil deteksi. Contohnya pada true positive (TP), nilai ini akan dihasilkan apabila model melakukan deteksi, dan memang benar secara nyata objek tersebut berhasil dideteksi. namun misalnya false positive (FP) dimana objek melakukan deteksi, namun pada box yang dideteksi ternyata tidak terdapat objek yang ditugaskan untuk dicari oleh model.

Tabel 1. Contoh tabel atribut.

Komponen	Keterangan	Kenyataan	Hasil
TP	True Positive	Ada	Ada
TN	True Negative	Tidak	Tidak
FP	False Positive	Tidak	Ada
FN	False Negative	Ada	Tidak

$$Precision = \frac{TP}{TP+FP} \quad (1)$$


$$Recall = \frac{TP}{TP+FN} \quad (2)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

Formula.(1) menunjukkan tingkat confidence model dalam melakukan prediksi yang benar. Formula (2) menunjukkan tingkat confidence model dalam mendeteksi contoh nyata positif dalam image. Formula (3) bertujuan untuk memperoleh skor F1 yang merupakan nilai rata-rata yang harmonis antara precision dan recall.


3. Hasil dan Pembahasan

Proses training dilakukan terhadap 2 model YOLOv9, yaitu YOLOv9-c dan YOLOv9-e. Setiap model akan dilatih sebanyak 3 putaran, yaitu 5 epoch, 25 epoch, dan 50 epoch, sehingga kini diperoleh 6 bobot yang bisa diuji untuk mencari bobot mana yang ideal kedepannya untuk digunakan pada aplikasi deteksi objek. Setiap model dilakukan proses validasi, untuk menguji kemampuan bobot yang akan menghasilkan confusion matrix, yang merupakan metrik untuk menampilkan sebaran hasil prediksi negatif dari sebuah model dalam sebuah matrix. Confusion Matrix akan menampilkan tingkat akurasi prediksi per-objek yang ditugaskan kepada model.




(a) (b)
Gambar 4. Confusion matrix (a) YOLOv9-c dengan (b) YOLOv9-e 50 epoch
Sumber: Penulis, 2025

Dari confusion matrix ini, bisa diperoleh gambaran mengenai bagaimana nilai TP, TN, FP, dan FN diperoleh. proses dilanjutkan dengan menggenerate nilai precision dan recall dari setiap bobot,



(a) (b)
Gambar 5. Kurva Precision (a), Recall (b) YOLOv9-c 5 epoch
Sumber: Penulis, 2025

Dari kurva precision dan recall, dapat dikalkulasi nilai F1 confusion matrix ini, bisa diperoleh gambaran mengenai bagaimana nilai TP, TN, FP, dan FN diperoleh. proses dilanjutkan dengan menggenerate nilai precision dan recall dari setiap bobot, yang dari nilai tersebut akan dapat menghasilkan nilai F1 sebagai kurva harmonisasi antara precision dan recall.




Gambar 6. Perbandingan F1-score YOLOv9-c (a) dengan YOLOv9-e (b) pada 50 epoch
Sumber: Penulis, 2025

Tabel 2. Hasil Validasi YOLOv9-c dan YOLOv9-e pada 5, 25, dan 50 epoch

Model	Epoch	Confusion matrix score	Precision	Recall	PR	F1
YOLOv9-c	5	0.87	1	0.98	0.870	0.84
YOLOv9-e	5	0.84	1	0.96	0.837	0.80
YOLOv9-c	25	0.93	1	0.95	0.919	0.88
YOLOv9-e	25	0.91	1	0.99	0.934	0.89
YOLOv9-c	50	0.98	1	0.98	0.960	0.94
YOLOv9-e	50	0.91	1	0.95	0.929	0.88

Model yang telah dilatih akan menghasilkan bobot yang dapat digunakan untuk melakukan deteksi terhadap 4% item dari data set yang telah ditentukan secara acak oleh roboflow sebagai data untuk pengujian. Pengujian deteksi objek dilakukan dengan tingkat confidence 0.5 sehingga hanya objek di atas nilai threshold tersebut yang akan terdeteksi. hasil deteksi ditampilkan pada gambar 7.



Gambar 7. Pengujian deteksi gambar untuk setiap model (a) YOLOv9-c 5 Epoch (b) YOLOv9-e 5 Epoch (c) YOLOv9-c 25 Epoch (d) YOLOv9-e 25 Epoch (e) YOLOv9-c 50 Epoch (f) YOLOv9-e 50 Epoch
Sumber: Penulis, 2025

4. Kesimpulan

Dari hasil pengujian di atas, Model YOLOv9 telah dibuktikan oleh penulis mampu untuk melakukan deteksi objek terhadap ikan lele yang tercecer di luar kolam. Proses pengujian dilakukan terhadap model YOLOv9-c dan YOLOv9-e menampilkan kemampuannya dalam proses deteksi dengan susunan dataset 88% untuk pelatihan, 8% untuk validasi, dan 4% untuk pengujian.

Dari hasil pengujian dengan metrik F1-score diperoleh model YOLOv9-c memiliki skor F1 paling tinggi pada 50 epoch. Namun YOLOv9-c dapat mendeteksi lebih banyak objek dengan tepat pada gambar uji coba pada 25 epoch. Mengingat setiap sub-model memiliki fungsi yang berbeda, sehingga untuk deteksi single-object yang bersifat lebih sederhana, model YOLOv9-c menunjukkan kemampuan yang lebih baik pada kasus deteksi ikan lele yang tercecer.

Saran untuk pengembangan kedepannya agar penelitian selanjutnya dapat memperkaya dataset baik dari kuantitas, kualitas, serta kategori dataset sehingga model dapat berkembang untuk menangani lebih banyak kasus dan memberikan manfaat yang lebih banyak lagi.

5. Ucapan Terima Kasih

Terimakasih saya ucapkan kepada segala pihak yang sudah membantu dalam mengembangkan karya tulis ini. Terimakasih kepada DRPM INSTIKI yang telah memberikan kesempatan untuk berkarya, terimakasih untuk Bapak I Gusti Made Ngurah Desnanjaya yang selalu memberikan inspirasi. Terimakasih kepada Bapak Anak Agung Gede Anom Adnyana selaku pemilik Pokdakan Mina Santi yang memberikan kesempatan untuk mengadakan penelitian pada area kolam yang dimiliki.

Daftar Pustaka (Heading 6, bold, 11 pt)

- Adnyana, A. A. G. O. K., Mahardika, I. G. I., Wicaksana, G. B. A., & Kotama, I. N. D. (2024). Classification Of Superstructure Damage In School Buildings In Nusa Penida Bali Using YOLO V7. *Jurnal Info Sains : Informatika Dan Sains*, 14(04), Article 04.
- Di, T., Feng, L., & Guo, H. (2023). Research on Real-Time Power Line Damage Detection Method Based on YOLO Algorithm. *2023 IEEE 3rd International Conference on Electronic Technology, Communication and Information (ICETCI)*, 671–676. <https://doi.org/10.1109/ICETCI57876.2023.10176923>
- Gheorghe, C., Duguleana, M., Boboc, R. G., & Postelnicu, C. C. (2024, December 1). *Analyzing Real-Time Object Detection with YOLO Algorithm in Automotive Applications: A Review*. | EBSCOhost. <https://doi.org/10.32604/cmes.2024.054735>
- Hastuti, S. W., & Herlina, S. (2020). Infestasi ektoparasit pada ikan Lele Dumbo (*Clarias gariepinus*) di Kelurahan Kuala Pembuang Dua. *JURNAL ILMU HEWANI TROPIKA (JOURNAL OF TROPICAL ANIMAL SCIENCE)*, 9(2), Article 2.
- Hidayati, S. N., Laili, S., & Santoso, H. (2021). Pengaruh Kualitas Air Kolam Terpal terhadap Pertumbuhan Ikan Lele Dumbo (*Clarias gariepinus*): Influence of Water Quality in the Tarpaulin Pool to the Dumbo Catfish (*Clarias gariepinus*) Growth. *Jurnal Ilmiah Biosaintropis (Bioscience-Tropic)*, 6(2), Article 2. <https://doi.org/10.33474/e-jbst.v6i2.314>
- Indonesia, B. P. S. (n.d.). *Produksi Perikanan Budidaya Menurut Komoditas Utama—Tabel Statistik*. Retrieved December 5, 2024, from <https://www.bps.go.id/id/statistics-table/2/MTUxMyMy/produksi-perikanan-budidaya-menurut-komoditas-utama.html>
- Jeong, D. (2020). Road Damage Detection Using YOLO with Smartphone Images. *2020 IEEE International Conference on Big Data (Big Data)*, 5559–5562. <https://doi.org/10.1109/BigData50022.2020.9377847>
- Kumar, P., & Shukla, P. K. (2025). Hybrid transformer-CNN model for precise Fish segmentation, localization, and species classification in aquaculture. *Journal of Integrated Science and Technology*, 13(6), Article 6. <https://doi.org/10.62110/sciencein.jist.2025.v13.1134>
- Li, J., Liu, C., Lu, X., & Wu, B. (2022). CME-YOLOv5: An Efficient Object Detection Network for Densely Spaced Fish and Small Targets. *Water*, 14(15), Article 15. <https://doi.org/10.3390/w14152412>
- Muksit, A. A., Hasan, F., Hasan Bhuiyan Emon, Md. F., Haque, M. R., Anwary, A. R., & Shatabda, S. (2022). YOLO-Fish: A robust fish detection model to detect fish in realistic underwater environment. *Ecological Informatics*, 72, 101847. <https://doi.org/10.1016/j.ecoinf.2022.101847>

- Rosales, M. A., Palconit, M. G. B., Almero, V. J. D., Concepcion, R. S., Magsumbol, J.-A. V., Sybingco, E., Bandala, A. A., & Dadios, E. P. (2021). Faster R-CNN based Fish Detector for Smart Aquaculture System. *2021 IEEE 13th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM)*, 1–6. <https://doi.org/10.1109/HNICEM54116.2021.9732042>
- Wang, C.-Y., Bochkovskiy, A., & Liao, H.-Y. M. (2022). *YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors* (No. arXiv:2207.02696). arXiv. <https://doi.org/10.48550/arXiv.2207.02696>
- Wang, C.-Y., Yeh, I.-H., & Liao, H.-Y. M. (2024). *YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information* (No. arXiv:2402.13616). arXiv. <https://doi.org/10.48550/arXiv.2402.13616>
- Wu, C., Ye, M., Zhang, J., & Ma, Y. (2023). YOLO-LWNet: A Lightweight Road Damage Object Detection Network for Mobile Terminal Devices. *Sensors*, 23(6), 3268. <https://doi.org/10.3390/s23063268>
- Yacouby, R., & Axman, D. (2020). Probabilistic Extension of Precision, Recall, and F1 Score for More Thorough Evaluation of Classification Models. In S. Eger, Y. Gao, M. Peyrard, W. Zhao, & E. Hovy (Eds.), *Proceedings of the First Workshop on Evaluation and Comparison of NLP Systems* (pp. 79–91). Association for Computational Linguistics. <https://doi.org/10.18653/v1/2020.eval4nlp-1.9>