

# 대형 해파리(*Nemopilema nomurai*) 탐지를 위한 머신러닝 기반 데이터 구축 및 모델 평가

오선영 · 김형태 · 이경훈<sup>1\*</sup>

국립부경대학교 해양생산관리학부 수산물리학전공, <sup>1</sup>국립부경대학교 해양생산시스템관리학부

## Machine Learning-based Data Construction and Model Evaluation for Monitoring of Giant Jellyfish *Nemopilema nomurai*

Sunyoung Oh, Hyungtae Kim and Kyoungsoon Lee<sup>1\*</sup>

Department of Fisheries Physis, Pukyong National University, Busan 48513, Republic of Korea

<sup>1</sup>Division of Marine Production System Management, Pukyong National University, Busan 48513, Republic of Korea

In this, we study developed a machine-learning system that can effectively detect giant jellyfish *Nemopilema nomurai* by collecting videos of their appearances. Surveys were conducted in the East China Sea, South Sea, and Jeju coastal waters, which are presumed to be jellyfish migration routes. Video data were collected using GoPro cameras, and images were extracted at 1 fps to train the YOLOv8 Nano and Medium models. The YOLOv8 Nano model achieved an F1 score of 0.83 with high confidence and maintained high precision in the precision-recall curve, demonstrating its effectiveness in predicting jellyfish occurrences. The YOLOv8 nano model demonstrated excellent reliability and precision, indicating its potential for effective jellyfish detection. However, to improve the performance of the model even further, data from various environments must be collected and additional validations must be performed.

Keywords: Giant jellyfish, Machine learning, YOLOv8, Precision-recall curve

### 서론

우리나라에 출현하는 해파리는 모두 124종이며, 이 중 100여 종이 독성이 있을 것이라 추정하였다(Yu, 2016; Lee et al., 2019). 여기서 대량으로 발생하여 사회·경제적 문제를 일으키는 종은 크게 노무라입깃해파리(*Nemopilema nomurai*)와 보름달물해파리(*Aurelia coerulea*)로 구분할 수 있다. 대형 동물플랑크톤으로 구분되는 노무라입깃해파리는 독성이 강한 자포를 지니고 있으며, 우산 크기는 약 2 m, 무게는 약 200 kg까지 성장하고, 동중국해를 통해 한국과 일본 연안에 대량으로 유입되는 것으로 알려져 있다(Lee, 2010; Oh et al., 2022; Chang and Ki, 2024). 동중국해 북부해역은 우리나라 남해를 포함하여 남쪽의 동중국해, 서쪽의 황해, 동쪽으로 대한해협을 통해 동해와 연결되는 통로로서 각 지역의 수계가 만나는 해역이다(Son et al., 2003). 최근 동중국해를 통해 유입되는 대형 해파리의 유입량이 증가하고 있고, 이는 어업, 해양 생태계, 관광 산업 등

에 심각한 영향을 미치고 있다(Kim et al., 2014). 대형 해파리의 대량 출현은 어업활동에서 어망을 손상시키고, 어획량을 감소시키며, 어획된 어획물의 신선도를 떨어트리는 등 경제적인 문제를 일으키고, 해수욕장에서는 해수욕객들에게 쓰임사고를 일으켜 위험을 초래하여 사회적인 문제를 일으킬 수 있다(Oh et al., 2024). 이러한 문제들을 해결하기 위하여 대형 해파리의 유입을 조기에 파악하고 대응하는 시스템이 필요하다.

대형 해파리의 유입을 조기에 파악하고, 신속하게 대응하기 위해서는 효율적인 시스템이 필요하며, 기존의 해파리 출현 조사는 주로 목시 관측, 과학어군탐지기를 이용한 음향조사, 음향 카메라, 채집어구를 이용한 네트 조사 등으로 이루어지고 있다(Lee et al., 2007; Yoon et al., 2012; Shin et al., 2019; Oh et al., 2024). 그러나 이러한 방법은 시간과 비용이 많이 소요되고, 해파리 출현을 신속하게 탐지하는데 한계가 있기 때문에 해파리 탐지를 위한 자동화 시스템 개발이 요구된다(Lee et al., 2007; Oh et al., 2021). 인공지능과 머신러닝 기술의 발전으로 국외에

\*Corresponding author: Tel: +82. 51. 629. 5889 Fax: +82. 51. 629. 5886

E-mail address: klee71@pknu.ac.kr



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

<https://doi.org/10.5657/KFAS.2024.0581>

Korean J Fish Aquat Sci 57(5), 581-588, October 2024

Received 5 August 2024; Revised 29 August 2024; Accepted 6 September 2024

저자 직위: 오선영(대학원생), 김형태(대학원생), 이경훈(교수)

서는 인공지능 기반의 인식 기법을 적용하여 취약한 어종 보호, 어류 개체수 파악 및 종 식별 등을 통한 해양 환경 및 수산 경제 연구들을 진행하고 있다(Holmboe, 2023; Jia et al., 2023; Park et al., 2023). 이러한 사례들은 해양 생태계 모니터링이 보다 정교하고 효율적으로 이루어질 수 있는 가능성을 보여주고 있으며, 머신러닝 기반의 탐지 시스템은 대량의 데이터를 처리하고 패턴을 분석하여 해양 피해를 예측할 수 있는 기반을 마련하였다(Abadal et al., 2020).

본 연구에서는 동중국해역과 우리나라 연근해에서 출현하는 대형 해파리를 대상으로 기존의 목시관측과 음향기법을 기반으로 한 방식을 보다 효과적으로 탐지하고 모니터링을 수행하기 위하여 머신러닝 기반의 데이터 구축 및 모델 평가를 분석하였다.

## 재료 및 방법

### 조사 해역

본 연구에서는 해파리의 이동경로로 추정되는 동중국해역에서 2022년 5월 28일부터 6월 5일까지 조사를 수행하였으며, 7월 1일부터 12일까지 남해와 제주 인근 해역에서 조사를 수행하였다(Fig. 1). 해상 조사는 국립수산과학원에서 수행하는 해파리 정밀조사에 동승하여 수행하였으며, 국립수산과학원 조사선 탐구 20호(R/V, 885G/T)와 탐구 21호(R/V, 999G/T)를 이용하였다.

### 영상 시스템 구축 및 자료 수집

영상자료를 수집하기 위하여 조사선 선교 양 현측에 카메라 한 대씩 하였다(Fig. 2). 카메라는 고프로(HERO9 Black; Go-Pro, San Mateo, CA, USA)를 사용하였고, 영상자료는 지넷시스템(KBR G1; GNET System, Seoul, Korea) 블랙박스 저장장치에 수집하였다. 영상자료는 해상도 1,080 p (16:9)로 설정하여 수집하였으며, 주간에 햇빛으로 인해 해면 반사가 발생했을

시, 영상 품질을 높이기 위해 CPL 편광필터를 장착하여 반사광을 차단하였다. 수집된 자료의 탐지 범위는 가로 약 10 m, 세로 약 4 m, 전체 면적 약 40 m<sup>2</sup>로 나타났다.

### 영상자료 분석

영상자료는 모든 정점에서 수집되었고, 정점별 영상 중 해파리가 출현한 정점에서의 자료를 바탕으로 분석하였다. 5월의 총 영상 개수는 357개로, 해파리의 출현 영상 개수는 143개로 나타났으며, 녹화된 영상 시간은 8시간 7분 57초이었고, 그 가운데 해파리가 출현한 시간은 3시간 35분 57초였다. 이와 같이 수집한 영상자료를 바탕으로, 1초마다 1 frame 단위로 이미지 12,957장을 추출하였다. 7월의 총 영상 개수는 1,298개로, 해파리의 출현 영상 개수는 54개였고, 전체 영상시간은 28시간 26분 44초였으며, 해파리가 출현한 시간은 1시간 28분 27초였다. 5월 영상과 동일하게 1초마다 1 frame 단위로 5,310개의 이미지를 추출하였다. 5월과 7월의 영상에서 총 18,267개의 모델 훈련 이미지 세트를 구축하였다. 해당 이미지들은 일자별 및 시간 대별로 구분하였고, 탐지하고자 하는 객체를 분류하여 설정하였다. 사진 내에 발견되는 해파리는 프로그램 VoTT (VoTT ver. 2.2.0, Microsoft, Redmond, WI, USA)와 Roboflow Website를 활용하여 라벨링 작업을 진행하였다. 이미지 내 출현하는 해파리에 대해 바운딩 박스(bounding box) 생성을 진행한 결과는 5월에 3,865장, 7월에 941장, 총 4,806장의 이미지를 라벨링하였다(Fig. 3).

이미지 세트를 구축한 후, (YOLO, Ultralytics Inc., Austin, TX, USA) Nano와 Medium을 이용하여 학습을 진행하였다. 모델의 성능 평가는 mAP (mean Average Precision) 외에도 F1 스코어, Precision-Recall 커브 등을 사용하였다. YOLOv8 Nano와 Medium의 성능 비교는 동일한 조건 하(Table 1)에서 수행되었으며, 각 모델의 정밀도와 속도 차이를 평가하였다.

Backbone 네트워크는 기본값인 CSP-Darknet53을 이용하였다. 또한, 해파리 탐지 데이터셋을 이용하여 모델을 생성하였

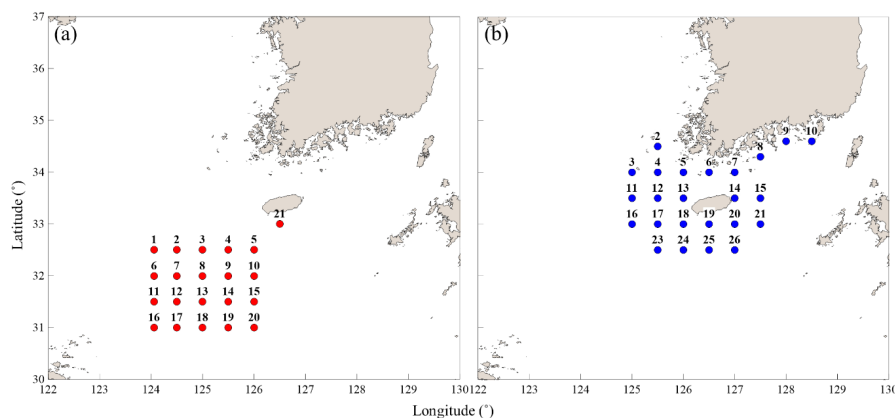


Fig. 1. Survey station. a, East China Sea; b, Coastal waters in Korea.

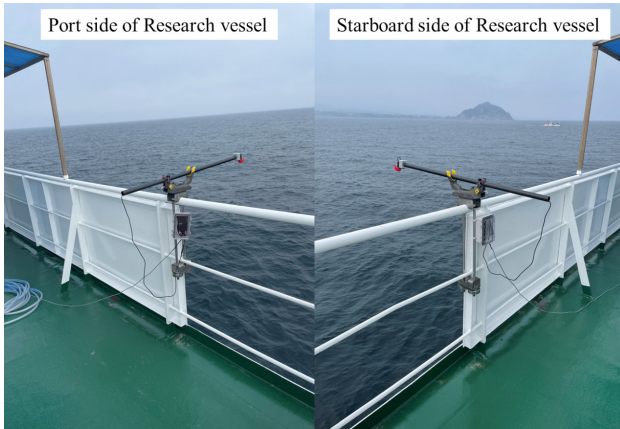


Fig. 2. Jellyfish *Nemopilema nomurai* observation camera installed on the research vessel.

Table 1. The parameters for different models of YOLOv8

	YOLOv8 nano	YOLOv8 medium
Epoch	300	300
Batch	24	24
Image size (imgsz)	640	640
Learning rate (lr0)	0.01	0.01
Weight decay	0.0005	0.0005

을 때 사용한 훈련 값은 IoU는 0.7, Epoch는 300, Conf.는 0.5, Batch는 24, Patience는 100으로 설정하였다.

## 결 과

본 연구에서는 YOLOv8 Nano 모델의 예측 신뢰도와 성능 간의 관계를 분석하기 위해 F1 점수와 confidence의 관계를 Fig. 4a에 나타내었다. 이를 통해 모델이 높은 신뢰도에서 얼마나 정




Fig. 3. Example of setting a bounding box.

확한 예측을 수행하는지 평가할 수 있다. 그 결과, 모델의 confidence 값이 증가함에 따라 F1 값이 감소하는 경향을 나타내었다. Confidence 값이 0.25일 때 F1은 최고점인 0.83을 나타내었지만, 0.5이상의 임계값부터 F1 값이 지속적으로 감소하였다. 이는 더 높은 confidence 값이 필터링을 더 정교하게 만들고, 이에 따라 모델이 보다 확실한 경우만을 예측하게 하여 F1 값이 떨어지는 경향을 나타낼 수 있다.

또한, Precision-Recall 곡선은 Fig. 4b에 나타내었다. 그림에서 모델은 낮은 재현율(0.001)에서 높은 정밀도(0.9)를 유지하는 것으로 나타났다. 이는 모델이 양성으로 예측한 사례 대부분이 실제로 양성임을 의미한다. 그리고, 재현율(0.8)이 증가함에 따라 정밀도가 감소하는 경향을 나타내었다. 이 결과는 재현율이 0.9에 도달했을 때, 정밀도는 0.003으로 급감하는 것을 나타냈는데, 이는 모델이 가능한 많은 양성 사례를 탐지하려는 과정에서 양성으로 예측한 사례 중 거의 대부분이 실제로는 음성임을 의미한다.

YOLOv8 Medium 모델의 예측 신뢰도와 성능 간의 관계를 분석하기 위해 F1 점수와 confidence의 관계를 Fig. 5a에 나타내었다. Medium 모델의 결과는 Nano 모델과 유사하게 나타났

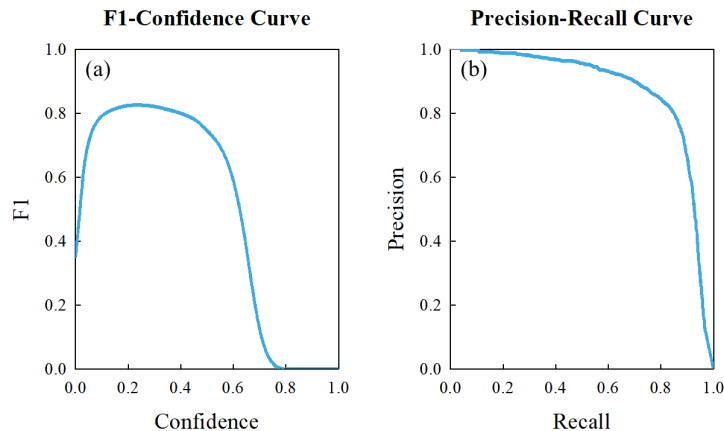


Fig. 4. Performance analysis of machine learning models using YOLOv8 Nano. a, F1-confidence; b, Precision-recall curves.

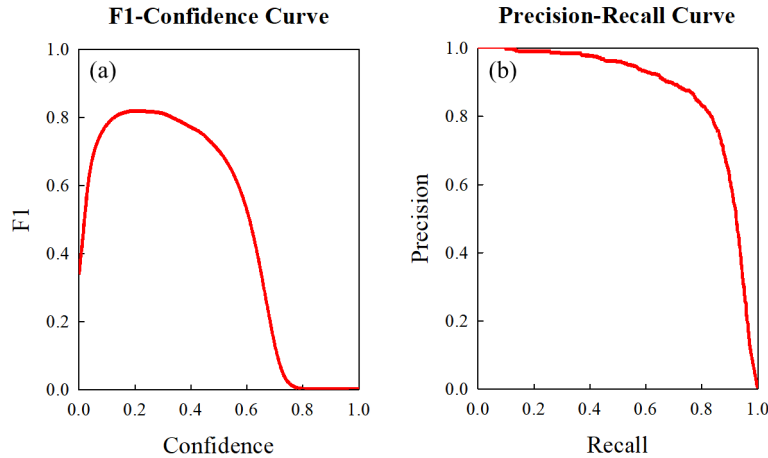


Fig. 5. Performance analysis of machine learning models using YOLOv8 medium. a, F1-confidence; b, Precision-recall curves.

다. Medium 모델 또한, confidence 값이 증가함에 따라 F1 값이 감소하는 경향을 나타내었고, confidence 값이 0.21로 증가할 때 F1은 상승하여 최고점인 0.82을 나타내었으며, 0.6 이상의 confidence 값에서는 F1 값이 꾸준히 감소하는 경향을 나타내었다.

YOLOv8 Medium 모델의 Precision-Recall 곡선은 낮은 재현율(0.001)에서 높은 정밀도(1.0)를 유지하였다(Fig. 5b). 이와 같은 결과는 Nano 모델과 유사하고, 재현율(0.8)이 증가함에 따라 정밀도가 감소하는 경향을 나타내었다. 정밀도가 높고 재현율이 낮으면 모델이 false positive를 줄이는 데 집중했음을 나타내며, 반대로 recall이 높고 precision이 낮으면 모델이 false negative를 줄이는 데 집중했음을 나타낸다.

YOLOv8 Nano 모델의 결과 값은 Fig. 6에 나타내었다. Nano 모델의 훈련 횟수에 따른 박스 손실은 점차 감소하였다. 초기 단계인 Epoch 1에서 박스 손실은 2.2515로 나타났고, Epoch 50에서 1.9820로 나타났다. 중간 단계인 Epoch 51에서 1.9806, Epoch 100에서 1.9054로 감소하였다. 후기 단계인 Epoch 101에서 1.9056, Epoch 195에서 1.6292로 박스 손실 값이 더 안정화되며, 미세하게 감소하였다. 박스 손실이 낮을수록 모델의 물체 위치를 더 정확하게 예측한다는 의미에서 학습과정의 박스 손실이 지속적으로 감소하는 것은 모델의 성능이 향상되고 있음을 나타내었다.

분류 손실은 모델의 객체의 클래스를 예측할 때 발생하는 손실을 의미하고, 값이 낮을수록 모델이 더 정확하게 객체의 클래스를 예측하고 있다는 것을 의미한다. 초기 Epoch 구성은 300이었지만, 성능 향상이 지속적으로 발생하지 않을 경우, 과적합 방지를 위해 설정한 Patience 값에 의하여 모델 훈련은 Epoch 195에서 조기 종료되었다. 학습 초기에는 분류 손실 값이 2.5919로 시작하여 훈련을 진행할수록 점차 감소하는 경향을 나타내었다. Epoch 50 이후에는 분류 손실 값이 점차 안정화되

었으며, 더 이상 큰 변동 없이 서서히 감소하였다.

Distribution focal loss (DFL)는 객체 검출 모델에서 사용되는 손실 함수 중 하나로, 객체의 위치를 예측하는 정확성을 높이기 위해 사용되며 객체의 바운딩 박스 위치를 더 정확하게 예측할 수 있도록 도와준다. Epoch 초기에 DFL 손실 값이 1.1397로 시작하였지만, Epoch 195에는 0.9655로 감소하였다.

정밀도(precision)는 모델이 예측한 양성 사례 중 실제로 양성인 사례의 비율이고, 높은 정밀도는 모델이 거짓 양성을 줄인 것을 의미한다. 초기의 정밀도 값은 급격히 증가하여 약 0.7756까지 도달하였다가 이후 0.7과 0.8 사이에서 값이 안정화되지 않았다. 마지막 Epoch에서 정밀도 값은 약 0.82에 도달하였으며, 모델이 새로운 데이터에 적응한 것을 알 수 있었다. 이러한 패턴은 모델이 초기에는 빠르게 학습하고 이후에는 점차 미세 조정이 이루어지는 일반적인 학습 곡선을 나타낸다.

재현율(recall)은 모델이 실제 양성 사례 중에서 올바르게 예측한 양성 사례의 비율을 나타낸다. 분석 결과, 초기에는 재현율 값이 빠르게 증가하여 0.7 이상 도달하였고, 중반 이후로는 다소 변동성을 나타내었지만 전반적으로 0.75에서 0.85 사이에서 유지되었다. 마지막 훈련에서는 재현율 값이 약 0.80에서 0.85 사이로 나타났으며, 이것은 대부분의 실제 양성 사례를 잘 식별하는 것을 의미한다.

mAP50 (mean average precision at 50% IoU threshold)은 물체 검출 모델에서 사용되는 성능 지표로, 모델이 50% IoU (intersection over union) 기준으로 얼마나 잘 검출하는지를 평가한다. 초기 mAP50 값은 0.6656에서 시작하여, 학습이 진행됨에 따라 0.8735까지 상승한다. 초기 성능은 정밀도와 재현율 모두 낮게 시작하지만, 학습이 진행되면서 점차 향상하였다.

mAP50-95 (mean average precision at IoU thresholds from 50% to 95%)는 다양한 IoU의 다양한 임계값에서 객체 검출 모델이 얼마나 일관되게 잘 작동하는지 평가하는 데 사용되는 지



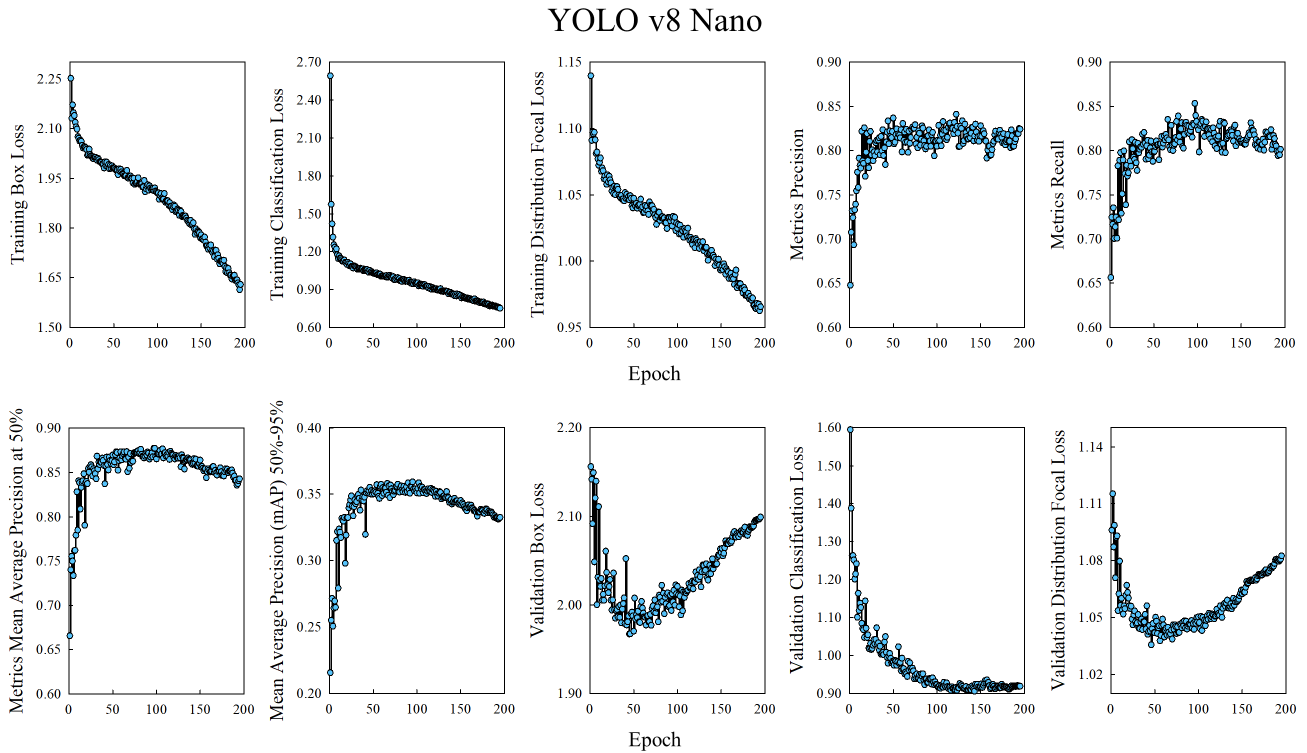


Fig. 6. Performance analysis of YOLOv8 nano: Training and validation metrics.

표이다. mAP50-95 값은 0.2156에서 시작하여, Epoch이 진행됨에 따라 0.3580까지 상승하였다. 초기값에 비하여 상당한 상승을 보였고, 전반적인 검출 성능이 개선되었다.

Validation box loss는 모델 학습 중 성능을 평가하기 위해 사용되는 데이터셋을 의미한다. 초기에 2.1561에서 시작하여 여러 번의 epoch를 거치며 변동을 나타내었다. 초기 epoch 동안 손실 값이 점차 감소하는 경향을 나타내었다가 2.0 부근에서 점차 안정화되었다. 하지만 epoch가 진행됨에 따라 손실 값은 다시 증가하는 경향을 나타내었다.

Validation classification loss는 모델이 검증 데이터셋에서 예측한 분류 결과와 실제 라벨 사이의 차이를 나타내는 손실 값이다. 초기의 손실 값은 1.5950에서 1.0847로 빠르게 감소하였다. 이것은 모델이 초기 학습 단계에서 데이터를 잘 학습하고 있음을 나타내는 것이다. 학습이 진행됨에 따라 값은 안정적으로 감소하였고, 후반에는 손실 값이 거의 변동하지 않았으며 학습이 안정화되었다.

Validation DFL loss는 모델이 검증 데이터셋에서 예측할 때의 손실을 나타내며, 주어진 값들을 분석하여 모델의 성능을 평가할 수 있다. Validation DFL loss의 전체적인 추세는 초기에 손실 값이 다소 높다가 점차적으로 안정화되는 경향을 나타낸다. 초기 epoch의 손실값은 1.0960으로 시작했다가 중간에 1.0415로 감소하여 안정적인 수준을 유지하였다. Epoch 150 이후에는 손실 값이 1.0561에서 1.0802로 다소 증가하지만 안

정적인 수준을 유지하였다. 이러한 결과는 모델이 검증 데이터셋에서 일관된 성능을 보여주고 있는 것을 의미한다.

YOLOv8 medium 모델의 결과 또한, 초기 epoch 구성은 300이었지만, 성능 향상이 지속적으로 발생하지 않을 경우, 과적합 방지를 위해 설정한 patience 값에 의하여 모델의 훈련은 epoch 134에서 조기 종료되었고 결과 값은 Fig. 7에 나타내었다. Medium 모델의 훈련 횟수에 따른 박스 손실은 nano 모델과 유사한 경향을 나타내었다. epoch 1부터 100까지의 값들은 전반적으로 감소하였고, 이는 모델이 학습을 통해 점차적으로 개선되고 있는 것을 나타낸다. 모델은 초기 학습 단계에서 손실 값을 2.2116에서 2.0424로 감소시키며 빠르게 학습하였고, 후반까지 안정적이게 유지하면서 점차 감소하였다.

분류 손실(train classification loss)의 결과는 epoch 1부터 100까지 전반적으로 감소하였다. 초기에 손실 값이 1.7711에서 1.1454로 급격하게 감소하였다가 후반에 지속적으로 0.6007까지 감소하였다.

DFL의 결과는 손실 값이 1.1283에서 0.9016으로 지속적으로 감소하는 추세를 보이고 있으며, 손실 값의 변동성이 낮아 모델의 예측이 일관되고, 과적합이나 학습 부족의 문제가 크지 않을 것으로 판단된다.

정밀도(precision)의 결과는 초기 학습 단계에서 모델이 학습하여 값이 0.7794에서 0.7554로 약간의 변동성을 나타냈다. 또한, epoch 50부터 값이 0.8185에서 증가하다가 epoch 100까지

## YOLO v8 Medium




Fig. 7. Performance analysis of YOLOv8 medium: Training and validation metrics.

0.8을 유지하였는데, 이후 0.7914로 감소하였다. 하지만 훈련이 지속되면서 0.7994로 증가하는 모습을 나타냈다.

재현율(recall)은 정밀도와 유사한 경향을 나타내었고, 모델이 초기 학습 단계에서 변동이 있었지만 전반적으로 유지되었으며, 안정적으로 학습되었다.

mAP50 (mean average precision at 50% IoU threshold)의 초기 값은 0.7977에서 시작하여, 학습이 진행됨에 따라 0.8269까지 상승하였다. 초기 성능은 정밀도와 재현율 모두 낮게 시작하지만, 학습이 진행되면서 점차 향상되었다.

mAP50-95 (mean average precision at IoU thresholds from 50% to 95%)는 초기에 0.3031에서 0.2888로 약간의 변동성을 나타냈다가 중간에 0.3535에서 0.3481로 안정적인 값을 유지하였다. 이후 0.3212에서 0.3185로 소폭 하락하지만, 전반적으로 안정적인 값을 유지하였다.

Validation box loss는 epoch 1부터 150까지 증가하는 경향을 나타내었고, 모델의 성능이 일정 지점 이후 감소하였다. 초기 값은 2.062에서 2.0037로 소폭 감소하였으나, epoch 50부터 값이 2.0219에서 2.0507로 약간 증가하였다. 이후 2.1887까지 증가하여 모델의 학습이 거의 완료된 상태에서 오류가 증가하였다. 이는 초기 학습 단계에서 오류가 감소하여 모델의 성능이 개선되고 있었으나, 중간 학습 단계에서 약간의 변동을 나타내었다.

Validation classification loss의 결과 값은 초기에 1.1879로 시작하여 중간 학습 단계에서 0.9284까지 감소하였다. 하지만 모

델의 학습이 거의 완료된 상태에서 값이 0.9611에서 0.9908로 증가하였고, 분류 오류가 약간 증가하였다.

Validation DFL loss는 epoch 1에서 1.0784으로 훈련을 시작하였고, 점차 1.0564까지 감소하였다. 하지만, 모델의 학습이 거의 완료된 상태에서 값이 1.1159로 증가하다가 1.1273까지 증가하여 성능이 다소 저하되는 경향을 나타내었다.

## 고 찰

두 모델 모두 초기 학습 단계에서 박스 손실이 크게 감소하지만, nano 모델이 epoch 195까지 지속적으로 감소하는 반면, medium 모델은 epoch 100까지 비교적 빠르게 감소한 후 안정화되었으며, nano 모델이 더 많은 epoch 동안 박스 손실을 줄이는데 효과적이었다. 분류 손실은 medium 모델이 nano 모델보다 감소폭이 더 크게 나타났으며, medium 모델이 분류 작업에서 더 빠르게 학습하고, 더 낮은 손실 값을 유지하여 객체의 클래스를 더 정확하게 예측하는 경향을 나타내었다. 선행연구인 Lin et al. (2017)에 의하면 객체 검출 모델의 성능을 크게 향상시키는 요인은 FL (focal loss)이라 보고하였고, 여기서 FL은 처리하기 어려운 샘플에 대해 모델이 잘 학습하도록 성능을 향상시키기 위하여 사용되는 손실 함수를 의미한다. 선행연구에서는 클래스간의 불균형 문제를 효과적으로 해결할 수 있다고 보고하였으며, 두 모델 모두 DFL에서 비슷한 경향을 보이며 손실

값이 지속적으로 감소하였고, medium 모델이 약간 더 빠르게 감소하여 안정화되었다.

재현율은 두 모델 유사한 성능을 나타내었다. mAP50은 nano 모델에서 mAP50 값이 더 크게 상승하였으며, 초기 성능이 낮았지만 학습을 통해 더 큰 개선되었다. Medium 모델 또한 초기 값은 높았지만 상승폭은 비교적 작게 나타났다. 두 모델 모두 mAP50-95에서 성능이 개선되었고, nano 모델이 더 큰 향상을 나타내었다. Nano 모델과 medium 모델 모두 학습을 통해 성능이 향상되었다. Nano 모델은 더 긴 학습 과정 동안 손실이 지속적으로 감소하고 성능이 향상되었고, medium 모델은 초기 학습 단계에서 더 빠르게 성능이 개선되지만, 후반에는 변동성이 다소 크게 나타났다. 전반적으로 nano 모델이 박스 손실과 정밀도에서 더 높은 성능을 보였고, medium 모델은 분류 손실에서 더 나은 성능을 나타내었다.

YOLOv8 nano와 medium의 실험 결과, nano 모델은 속도 면에서 우수했지만, 정밀도는 medium 모델이 더 높았다. 특히, 영상의 품질이 떨어지는 환경에서는 medium 모델이 더 나은 성능을 보였다. 선행연구인 Recht et al. (2019)의 연구와도 일치하는 것으로 나타났다. 일반적으로 모델이 더 정확하게 탐지하려면 복잡한 구조를 가져야 하는데, 이것은 계산 시간이 늘어나 속도가 느려질 수 있는 단점을 가지고 있다. 이러한 단점을 보완하기 위하여 nano 모델과 같은 경량화된 모델을 사용한다. Nano 모델은 계산량이 적기 때문에 더 빠른 처리 속도를 제공하지만 복잡한 구조를 이루는 장면에서는 정밀도가 떨어질 수 있는 단점이 있다(Huang et al., 2017).

본 연구와 유사한 연구인 Pham et al. (2024)은 YOLO v5 nano 모델을 이용하여 15가지 다른 유형의 해파리를 다양한 모양, 색상, 해상도 및 배경을 분류하여 탐지하였고, Weihong et al. (2023)의 연구에서는 해파리 예측이 어려운 문제를 해결하기 위해 세 종류의 해파리를 포함한 데이터셋을 구축하고 3가지 모델을 이용하여 비교 분석하였다. 다른 연구에서는 수중카메라로 수집한 여섯 종류의 해파리를 다양한 모델을 이용하여 분석한 결과, YOLOv8 모델이 가장 우수한 성능을 나타내었다(Nawarathne et al., 2024). 선행연구인 Abadal et al. (2020)에 의하면 수중 촬영하여 수집한 이미지로 해파리를 탐지했을 때, 정밀도, 재현율, F1 및 mAP 등에서 높은 성능을 보였지만, 수집된 이미지의 품질이 해파리 검출 성능에 영향을 끼치고, 다양한 해양 환경 및 조건에서 일관된 성능을 보장하기 위해서는 더 많은 자료와 검증을 거쳐야 한다고 보고하였다. 최근에는 여러 객체탐지모델을 사용하여 해파리 종에 대한 모델별 탐지 성능 비교 및 검증과 관련된 연구가 지속되고 있다. 하지만, 대부분의 선행연구들은 수중카메라를 이용하여 이미지를 수집하여 분류하였다. 본 연구는 목시조사가 이루어질 때 해수면 위에서 수집한 영상 자료를 기반으로 분석하였다. 해파리는 해수면에 부유하며 유영하는 특성가지고 있으며, 이러한 특성을 이용한 객체 탐지 연구이다. 현재 연구의 한계점으로는 데이터의 다양성이

부족한 점이 있고, 향후 다양한 환경에서의 데이터를 수집하고, 해파리와 수색이 비슷한 상황에 따른 데이터 전처리 과정 및 클래스 설정에 대한 다양화 및 자세한 기준을 설정하여 모델의 성능을 향상시킬 계획이다.

## 사 사

이 논문은 2023년 국립부경대학교 자율창의학술연구비(지속 가능한 어업자원평가 향상에 관한 연구, 202407060001)의 지원을 받아 수행되었으며, 본 논문을 사려 깊게 검토하여 주신 심사위원님들과 편집위원님께 감사드립니다.

## References

- Abadal M, Frau A, Hinz H and Cid Y. 2020. Jellytoring: Real-time jellyfish monitoring based on deep learning object detection. *Sensors* 20, 1708. <http://dx.doi.org/10.3390/s20061708>.
- Chang SJ and Ki JS. 2024. Population characteristics of the venomous giant jellyfish, *Nemopilema nomurai*, found in the Yellow and Northern East China Seas. *J Environ Sci Int* 33, 87-95. <https://doi.org/10.5322/JESI.2024.33.1.87>.
- Holmboe J. 2023. Fish tracking using detection in Aquaculture: A pilot study. M.S Thesis, Norwegian University of Life Sciences, Trondheim, Norway.
- Huang J, Rathod V, Sun C, Zhu M, Korattikara A, Fathi A, Fischer I, Wojna Z, Song Y, Guadarrama S and Murphy K. 2017. Speed/accuracy trade-offs for modern convolutional object detectors. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 7310-7311.
- Jia R, Lv B, Chen J, Liu H, Cao L and Liu M. 2023. Underwater object detection in marine ranching based on improved YOLOv8. *J Mar Sci Eng* 12, 55. <https://doi.org/10.3390/jmse12010055>.
- Kim DY, Lee JS and Kim DH. 2014. A study on direction of industrial utilization for jellyfish in Korea. *J Fish Mar Sci Edu* 26, 587-596. <https://doi.org/10.13000/JFMSE.2014.26.3.587>.
- Lee D, Han I, Chae J, Yoon W, Yang Y, Kim D and Lee K. 2019. Analysis of the advantage and disadvantage of harmful jellyfish's damage reduction devices strategy types in the beach. *The J Fish Mar Sci Edu* 31, 1230-1241. <https://doi.org/10.13000/JFMSE.2019.8.31.4.1230>.
- Lee HY. 2010. Reproduction and feeding behavior of giant jellyfish, *Nemopilema nomurai* Kishinouye (Scyphozoa: Rhizostomeae). Ph. D. Thesis, Pukyong National University, Busan, Korea.
- Lee KH, Kim IO, Yoon WD, Shin JK and An HC. 2007. A study on vertical distribution observation of giant jellyfish (*Nemopilema nomurai*) using acoustical and optical methods. *J Kor Soc Fish Tech* 43, 355-361. <https://doi.org/10.3796/KSFT.2007.43.4.355>.

- Lin TY, Goyal P, Girshick R, He K and Dollar P. 2017. Focal loss for dense object detection. In: Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV), 2980-2988.
- Nawaeathne U, Kumari H and Kumari H. 2024. Comparative analysis of jellyfish classification: A study using YOLOv8 and pre-trained models. In: 2024 International Research Conference on Smart Computing and Systems Engineering (SCSE), Colombo, Sri Lanka, 1-6. <http://dx.doi.org/10.1109/SCSE61872.2024.10550783>.
- Oh S, Kim KY, Lim WA, Park G, Oh H, Oh W and Lee K. 2021. Vertical distribution of giant jellyfish (*Nemopilema nomurai*) in the coastal waters of Korea and its correlation analysis by survey method. J Koran Soc Fish Ocean Technol 57, 351-364. <https://doi.org/10.3796/KSFOT.2021.57.4.351>.
- Oh S, Kim KY, Oh HJ, Park G, Oh W and Lee K. 2022. Spatio-temporal distribution of giant jellyfish (*Nemopilema nomurai*). Water 14, 2883. <https://doi.org/10.3390/w14182883>.
- Oh S, Kim KY, Youn SH, Lee S, Park G, Oh W and Lee K. 2024. A three-year comparison of fluctuations in the occurrence of the giant jellyfish (*Nemopilema nomurai*). Water 16, 2265. <https://doi.org/10.3390/w16162265>.
- Oh S, Kim KY, Youn SH, Lee S, Park G, Oh W and Lee K. 2024. Density estimation of giant jellyfish (*Nemopilema nomurai*) using a scientific echosounder. J Korean Soc Fish Ocean Technol 60, 18-26. <https://doi.org/10.3796/KSFOT.2024.60.1.018>.
- Park G, Bak S, Jang S, Gong S, Kwak J and Lee Y. 2023. Real-time detection of benthic marine invertebrates from, underwater images: A comparison between YOLO and transformer models. Korean J Remote Sens 39, 909-919. <https://doi.org/10.7780/kjrs.2023.39.5.3.3>.
- Pham TN, Nguyen VH, Kwon KR, Kim JH and Huh JH. 2024. Improved YOLOv5 based deep learning system for jellyfish detection. IEEE Access 12, 87838-87849. <http://dx.doi.org/10.1109/ACCESS.2024.3405452>.
- Recht B, Roelofs R, Schmidt L and Shankar V. 2019. Do imageNet classifiers generalize to imageNet?. In: Proceedings of the 36th International Conference on Machine Learning. Long Beach, CA, U.S.A., 5389-5400.
- Shin HH, Han I, Oh W, Chae J, Yoon E and Lee K. 2019. Estimation of moon jellyfish *Aurelia Coerulea* using hydroacoustic method off the Coast of Tongyeong, Korea. Korean J Fish Aquat Sci 52, 725-734. <https://doi.org/10.5657/KFAS.2019.0725>.
- Son YT, Lee SH, Lee JC and Kim JC. 2003. Water masses and frontal structures in winter in the Northern East China Sea. J Korean Soc Oceanog 8, 327-339.
- Weihong B, Yun J, Jiaxin L, LingLing S, Guangwei F and Wa J. 2023. In-situ detection method of jellyfish based on improved fater R-CNN and FP16. IEEE Access 11, 81803-81814. <http://dx.doi.org/10.1109/ACCESS.2023.3300655>.
- Yoon EA, Hwang DJ, Shin HH, Gwak DS and Cha CP. 2012. *In Situ* acoustic characteristics of the large jellyfish *Nemopilema nomurai* in the East China Sea. J Kor Soc Fish Tech 48, 256-268. <http://dx.doi.org/10.3796/KSFT.2012.48.3.256>.
- Yu WB. 2016. Study on the rDNA characteristics of harmful jellyfishes *Aurelia* sp.1 and *Nemopilema nomurai* in Krea. M.S. Thesis, Sangmyung University, Seoul, Korea.