

http://dx.doi.org/10.17703/JCCT.2022.8.3.571

JCCT 2022-5-71

## 데이터 선별 및 클래스 세분화를 적용한 실시간 해양 침적 쓰레기 감지 AI 시스템 구현과 성능 개선 방법 연구

### A Study on the Implementation of Real-Time Marine Deposited Waste Detection AI System and Performance Improvement Method by Data Screening and Class Segmentation

왕태수\*, 오세영\*\*, 이현서\*\*\*, 최동규\*\*\*\*, 장종욱\*\*\*\*\*, 김민영\*\*\*\*\*

Tae-su Wang\*, Seyeong Oh\*\*, Hyun-seo Lee\*\*\*, Donggyu Choi\*\*\*\*\*,  
Jongwook Jang\*\*\*\*\*, Minyoung Kim\*\*\*\*\*

**요약** 해양침적쓰레기는 유령어업으로 인한 폐어구들로 인해 많은 피해와 쓰레기 추정량 편차 증가 등의 문제를 일으키는 주요 원인이 된다. 본 논문에서는 폐어구 사용량, 유통량, 유실량, 회수량에 대한 실태 파악을 위해 실시간 해양침적쓰레기 감지 인공지능 시스템을 구현하고, 성능 개선을 위한 방법에 대해 연구한다. 실시간 객체인식에 우수한 성능모델인 yolov5모델을 활용하여 시스템을 구현하였고, 성능개선 방법으로는 학습데이터의 '데이터 선별 과정'과 '클래스 세분화' 방법을 적용하였다. 결론적으로 비선별된 데이터셋과 클래스가 세분화된 데이터셋의 객체인식 결과보다 불필요한 데이터를 선별하거나 특징 및 용도에 따라 유사 항목을 세분화 하지 않은 데이터셋의 객체인식 결과는 해양침적쓰레기 인식에 개선된 결과를 보인다.

**주요어** : 해양침적쓰레기, yolov5, 딥러닝, 데이터사이언스, 객체인식

**Abstract** Marine deposited waste is a major cause of problems such as a lot of damage and an increase in the estimated amount of garbage due to abandoned fishing grounds caused by ghost fishing. In this paper, we implement a real-time marine deposited waste detection artificial intelligence system to understand the actual conditions of waste fishing gear usage, distribution, loss, and recovery, and study methods for performance improvement. The system was implemented using the yolov5 model, which is an excellent performance model for real-time object detection, and the 'data screening process' and 'class segmentation' method of learning data were applied as performance improvement methods. In conclusion, the object detection results of datasets that do screen unnecessary data or do not subdivide similar items according to characteristics and uses are better than the object recognition results of unscreened datasets and datasets in which classes are subdivided.

**Key words** : Marine Deposited Waste, yolov5, Deep Learning, Data Science, Object Detection

\*준회원, 동의대학교 컴퓨터 공학과, 석사과정 (제1저자)

\*\*준회원, 동의대학교 IT융합학과 석사과정 (참여저자)

\*\*\*준회원, 동의대학교 산업ICT기술공학과 학부생 (참여저자)

\*\*\*\*정회원, 동의대학교 스마트IT연구소 선임연구원 (참여저자)

\*\*\*\*\*정회원, 동의대학교 컴퓨터공학과 교수 (참여저자)

\*\*\*\*\*정회원, 동의대학교 ICT융복합연구소 조교수 (교신저자)

접수일: 2022년 4월 28일, 수정완료일: 2022년 5월 4일

게재확정일: 2022년 5월 8일

Received: April 28, 2022 / Revised: May 4, 2022

Accepted: May 8, 2022

\*\*\*\*\*Corresponding Author: kmyco@deu.ac.kr

Research Institute of ICT Fusion and Convergence, Dong-eui Univ., Korea

## I. 서론

해양쓰레기는 분포장소에 따라 해안 쓰레기, 부유 쓰레기, 침적 쓰레기로 분류한다[1]. 해양침적쓰레기는 바다에 유입되어 해저에 가라앉은 해양쓰레기이다. 해양 환경정보포털에 따르면 해양쓰레기 발생 원인을 육상 기인과 해상기인으로 나누고 있다. 먼저 육상기인은 육상에서 발생하는 쓰레기들이 태풍에 의해 바다로 유입되거나 해변에 출입하는 관광객에 의해 유입되는 것을 말한다. 해상기인은 어업, 낚시 활동 관련 행위로 인하여 해양 유입 되는 것을 말한다[2]. 이와 같이 해양쓰레기 발생 및 해양 유입이 지속적으로 증가하면서 저서 환경 및 생태계에 큰 위협이 된다. 특히 해양침적쓰레기는 유령어업(Ghost fishing)으로 인한 어획량 감소를 초래하여 연간 약 3,700억 원의 피해를 발생시킨다.

2020년 국가 해안쓰레기 모니터링 결과에 따르면 최근 3년간(2018년 ~ 2020년) 해양침적쓰레기가 2만 9000톤으로 전체 해양쓰레기 수거량 중에 25%를 차지한다. 해양쓰레기 전체 수거량은 2018년 4만 8000톤에서 2020년 11만 2000톤으로 2배 이상 증가했지만 해양침적쓰레기는 2018년 4만 2000톤에서 2020년 1만 8000톤으로 57% 감소했다[3]. 이는 부유쓰레기가 날씨 영향으로 해안으로 유입되면서 전체 수거율은 높아지고 상대적으로 수거가 어려운 해양침적쓰레기는 낮아지면서 생긴 결과이다. 이에 정부는 인공위성과 드론을 활용한 ICT 기반 모니터링 체계로 개편하는 제 1차(2021년 ~ 2030년) 해양폐기물과 해양 오염퇴적물 관리 기본계획을 발표했다[4].

본 논문에서는 해양에서 운영이 가능한 무인이동체에 적용 가능한 실시간 해양침적쓰레기 감지 AI 모델을 구현하고 데이터 선별과 클래스 세분화를 적용한 실시간 감지 AI모델 성능을 개선하고자 한다.

## II. 관련연구

시스템 설계 및 구현을 위해 폐어구로 인한 유령어업의 영향과 관련 객체 인식 모델 학습 알고리즘에 대해 살펴본다.

### 1. 폐어구로 인한 유령어업의 영향

유령어업(Ghost fishing)이란 바닷속에 버려진 폐어구

(Discarded fishing gear)에 해양생물이 걸려 죽거나 다치는 현상이다. 이는 바다에 버려진 폐그물과 같은 폐어구가 해양생물을 가두고 또 다른 해양생물이 폐어구로 유인되면서 폐어구 속에서 죽는 악순환이 반복된다. 이와 관련된 실험을 진행한 논문[5]에서는 해양생물이 폐어구에서 탈출 가능성에 대한 통발실험에서 76%의 해양생물이 폐어구를 탈출하지 못했다. 또한 폐어구에서 죽은 해양생물에 유인되는 자망실험에서는 18%의 해양생물이 그물에 걸렸다. 해양 수산부에 따르면 국내 연간 어획량은 10% 정도의 해양생물이 유령어업으로 인한 폐사를 당하고 있으며 폐어구에 의한 선박사고는 전체의 13%로 나타난다. 우리나라의 경우 연간 해양 플라스틱 쓰레기 발생량의 54%가 폐어구에 해당한다. 또한 폐어구는 단위당 무게가 크기 때문에 수거 성공 여부에 따라 동일 해역 내에서도 전체 쓰레기 추정량의 편차가 커질 수도 있다[6]. 이러한 문제를 해결하기 위해서 각 어구의 사용량과 유통량과 유실량, 회수량에 대한 실태 파악이 중요하다[7].

### 2. 객체 인식 모델 학습 알고리즘

컴퓨터 비전에서 사진을 분석하여 그 안에 있는 사물의 종류를 인식하는 객체 인식 분야에서는 CNN(Convolutional Neural Network)을 딥러닝 학습 알고리즘으로 많이 사용한다. 본 논문에서는 여러 관련 알고리즘 중에서 Faster R-CNN과 YOLO를 중점적으로 비교를 한다.




그림 1. Faster R-CNN 구조  
Figure 1. Structure of Faster R-CNN

#### 1) Faster R-CNN

그림 1은 Faster R-CNN의 전반적인 구조이다[8]. Faster R-CNN은 동일한 컨볼루션 네트워크에서 객체 감지 및 후보 영역 생성을 수행하면서 후보 영역 추출

네트워크를 적용해서 추출된 기능 맵을 후보 영역으로 추정하여 객체를 인식한다. 이를 통해서 기능 맵이 입력 이미지 보다 해상도가 낮아 연산이 줄어들어 Faster R-CNN이 Fast R-CNN보다 학습 속도가 빠르다는 장점을 가진다. 또한, 더 작은 RoI 연산으로 높은 정확도를 가진다.

## 2) YOLO




그림 2. YOLO 네트워크 아키텍처  
 Figure 2. Network Architecture of YOLO

그림 2는 YOLO의 네트워크 아키텍처이다[9]. 이 구조를 보면 후보 영역을 추출하기 위해서 별도의 네트워크를 적용하지 않는 1단계 객체 인식 구조이다. 또한, GoogLeNet가법을 응용하여 연산량을 감소하면서 층을 깊게 쌓는 방식을 사용하면서 학습속도가 빠르다. YOLO와 Faster R-CNN은 둘 다 CNN을 기반으로 성능을 개선한 모델로 앙커 박스 기반 네트워크 구조를 사용하여 회귀로 경계를 구분한다는 공통점이 있다. 하지만, YOLO가 분류와 바운더리 박스 회귀를 동시에 수행한다는 점에서 차이점이 있으며 학습속도와 추론 속도가 빠르다[10].




그림 3. Faster R-CNN, R-FCN, SSD, YOLO의 FPS 비교  
 Figure 3. FPS comparison between Fast R-CNN, R-FCN, SSD, and YOLO

그림 3은 해상도가 다른 입력 이미지를 사용하여 Faster R-CNN, R-FCN, SSD 및 YOLO 모델의 FPS를

비교한 이미지이다. FPS(초당 프레임 수)는 추론시간과 관련해 객체 인식 분야에서 중용하게 판단하고 있는 지표이다. 그림 3을 참고하자면, Faster R-CNN은 평균 11 FPS를 가지고, YOLO는 평균 65 FPS를 가진다[11]. 이를 통해 YOLO가 Faster R-CNN 보다 Frame rate (프레임 속도)가 높은 것을 알 수 있다. 실시간 객체 탐지에서는 정확도도 중요하지만, 그 물체를 빠르게 탐지하는게 중요하다. 그래서 본 논문에서는 실시간 객체 감지 성능이 우수한 YOLO를 해양침적쓰레기 감지 학습 알고리즘으로 사용한다.




그림 4. Yolov5, EfficientDet 모델의 정확도 및 GPU속도 비교  
 Figure 4. Graph comparing the yolov5 models with the COCO AP value and GPU speed of the effective det model

그림 4는 YOLOv5 모델과 EfficientDet 모델의 COCO AP value 및 GPU Speed를 비교하는 그래프다 [12-13]. COCO AP value는 256 ~ 1536의 다양한 추론 크기에 대해 5000 이미지 COCO val2017 데이터 세트에서 측정된 mAP@0.5:0.95 메트릭을 나타낸다. GPU Speed는 배치 크기 32의 AWS p3.2배 큰 V100 인스턴스를 사용하여 COCO val2017 데이터 세트에서 이미지 당 평균 추론 시간을 측정한다. 그림 4의 그래프를 보면 YOLOv5가 EfficientDet보다 정확하고 빠른 것을 알 수 있다. YOLOv5 또는 Faster R-CNN을 활용하여 객체 인식을 적용한 연구로 다양한 연구들이 진행되고 있다[14-16].

## III. 시스템 설계

시스템 설계에서는 시스템 구성과 Flow Chart, 덤핑을 위한 학습 데이터에 대해 살펴본다.

### 1. 시스템 구성




그림 5. 해양침적쓰레기 감지 AI 시스템  
Figure 5. Marine Deposited Waste Detection AI System

그림 5는 구현할 감지 시스템 구상도이다. 해당 시스템은 무인이동체의 카메라로부터 실시간으로 해양침적쓰레기가 있는 장면을 입력받아 YOLO로 해양침적이미지 데이터를 사전에 학습한 AI모델을 통한 침적쓰레기 감지 결과를 전달하여 사용자에게 해양침적쓰레기 현황을 모니터링할 수 있게 해준다.

## 2. 시스템 전체 흐름

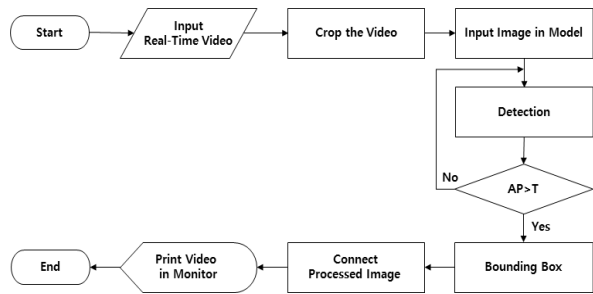


그림 6. 시스템 흐름도  
Figure 6. System Flow Chart

그림 6은 해양침적쓰레기 감지 AI 시스템의 흐름도이다. 시스템 흐름은 먼저 카메라로부터 받은 영상을 프레임별로 이미지를 자른다. 이미지에서 앵커를 기준으로 검출을 진행하면서 정확도가 임계값(T) 보다 높으면 객체를 중심으로 박스 처리를 한다. 모든 프레임 이미지에 대해서 검출을 마쳤다면 이미지를 다시 합쳐 사용자에게 모니터링 동영상으로 출력한다.

## 3. 학습데이터

### 1) 학습데이터 정의

해양 속 시계(시아)는 매우 불규칙하다. 그 이유는 다양한 환경적 요인(바람, 지역, 지형, 해저구성, 조수, 계절, 생태환경)이 해양 시계에 큰 영향을 미치기 때문이다. 이 요인들로 인해 해양 속 시계는 좁고 흐릿한 경우가 빈번하다[17]. 좁은 시계 속에서 이루어지는 해양

환경조사를 고려하여 해양에서의 다양한 시계 데이터가 필요했다. 또한, 인지하고자 하는 해양 침적 쓰레기 데이터의 경우 침적으로 인한 형태나 특징이 변형되기 때문에 일반 쓰레기 데이터가 아닌 가라앉은 침적 쓰레기 데이터가 필요했다[18]. 전체 해상사고의 13%에 달하는 선박 부유물 감김 사고와 수산업에 큰 피해를 주는 유령어업 같은 경우 폐그물, 로프, 통발 등 폐어구로 인해 가장 많이 발생하는 것을 고려하여 학습 데이터의 객체는 폐어구로 정의했다[19]. 이와 같이 학습 데이터를 정의하는 이유는 특수한 환경에서의 데이터 품질에 대한 분류가 인공지능의 실시간 검출 정확도를 높일 것이라 가정했기 때문이다.

### 2) 데이터 선별

테스트 설계를 위한 학습 데이터는 AI-Hub 사이트의 ‘해양 침적 쓰레기 이미지 데이터’를 사용했다 [20-21]. 해당 데이터 셋은 해양 침적 쓰레기의 수거를 위해 실시, 설계 조사를 보다 빠르고 효율적으로 수행하고자 조사 과정에서 생성되는 다양한 시계가 포함된 수중 촬영 이미지 데이터 셋이다.

표 1. 데이터 선별 기준

Table 1. Data Screening Criteria

Data Screening Criteria
1. Does the object in the data clearly exist?
2. Does the object exist in the data intact?
3. Has the object been immersed for a long time and assimilated into the environment? ( Improvement of object recognition accuracy, It has been assimilated by immersion for a long time and cannot be recognized as garbage. )

수중 촬영 이미지는 총 15,000개이며, 표 1의 기준에 따라 데이터를 선별했다. 학습 데이터는 정확한 인식을 위해 너무 낮은 화질이나 이미지 속 객체가 불분명하지 않고 명확하게 존재해야 하며, 이미지 속 객체가 부분적으로 존재하거나 너무 오래된 침적으로 인해 환경과 동화되어 있지 않아야 한다.

그림 7은 데이터 선별 기준에 따라 제외된 이미지 예시들이며, 데이터 선별과정을 거친 학습데이터는 8,856개의 이미지로 구성했다. 같은 객체이지만 특징 및 형태나 용도가 다른 객체들은 정확한 인식을 위해 세분화하여 클래스를 지정했다. 통발 같은 경우 원형, 사각형,




그림 7. 데이터 선별 기준에 따라 제외된 이미지 예시  
 Figure 7. Examples of images excluded by data screening criteria

육각형 등 형태가 다양하지만 잡는 어류의 종류에 따라 그 통발의 특징과 모양이 결정되기도 한다. 장어 통발 같은 경우 유연한 장어를 포획하기 위해 플라스틱 재질의 긴 원기둥 모양을 가지고 있다. 데이터 감지 항목은 Rope(밧줄), Fish\_net(그물), Cir\_trap(원형통발), Rec\_trap(사각형통발), eel\_trap(장어통발), Tire의 6개 클래스로 구성했다.

### 3) 데이터 라벨링

데이터 학습 전 정확도와 객체인식 향상을 위한 클래스 별 기준을 통한 라벨링 작업이 요구되었다. 표 2는 라벨링 과정에서 적용한 클래스 별 기준이다. 객체인식 정확도를 높이기 위해 클래스 별로 뚜렷한 모양이나 각도, 객체의 고유 특징 등 객체를 정의할 수 있는 기준을 설정하여 라벨링 작업을 실시했다.

표 2. 클래스 별 라벨링 기준  
 Table 2. Labeling criteria for each class

Class	Labeling criteria
rope	Three-strand twisted rope ( S-twist or Z- twist )
fish_net	The shape of the fishnet mesh is square or rhombus
cir_trap	The shape of the trap entrance is round
rec_trap	The shape of the trap is a hexahedron, and there is a vertex where the X-Y-Z axes meet.
eel_trap	There is a drain hole and there is a guide hole hinge
tire	There's a tire wheel hole, and it's shaped like a hole (circular or elliptical).

어구로 쓰이는 rope(밧줄) 같은 경우 강도를 유지하기 위해 실로 꼬아 만든 3개의 끈줄을 서로 다시 꼬아

만든 ‘세 가닥 끈 로프’를 주로 사용한다. 세 가닥으로 꼰 때 S자 또는 Z자 형태로 꼬이기 때문에 rope에 사선의 무늬가 형성된다[22]. fish\_net(그물) 같은 경우 실들이 만나는 꼭지점들 사이의 공간인 ‘그물눈’의 모양이 사각형 또는 마름모 형태로 나타나게 된다. cir\_trap(원형 통발)은 원기둥 모양의 형태를 띄며 통발 입구의 단면이 원의 형태를 띄고 있다. 훼손되지 않게 양쪽면이 유지된 통발은 양쪽 단면의 원형을 포함하여 라벨링 작업을 수행하였고 한쪽 면이 훼손된 경우 훼손되지 않은 한쪽 단면의 원형만 라벨링 작업을 수행했다. rec\_trap(사각형 통발)은 육면체의 형태를 띄며 사각형 모양의 면을 가지고 있기 때문에 X-Y-Z축이 만나는 꼭지점이 존재한다. eel\_trap(장어 통발)은 여러 형태를 가지고 있지만 물이 빠져나가는 배수구와 통발 입구의 유도구를 고정하기 위한 경첩이 존재한다. 배수구 구멍이 존재하고 유도구 경첩을 포함하게끔 라벨링 작업을 수행했다. tire(타이어)의 경우 크기가 다양하지만 원형의 형태를 띄며 자동차 휠 구멍이 존재한다. 침적된 페타이어에 휠 구멍이 있고 모양이 원 또는 타원형인 타이어만 라벨링 작업을 수행했다.




그림 8. 클래스 별 라벨링 기준에 따른 라벨링 이미지  
 Figure 8. Labeling images for each class according to the criteria

그림 8은 표 2의 클래스별 라벨링 기준에 따른 라벨링 이미지이다. 학습데이터 셋 완성을 위해 데이터를 정의하고 기준에 따른 데이터 분류 작업 후 객체 특징에 따른 라벨링 작업까지 진행하여 학습데이터 셋을 완성했다.

#### IV. 구현 및 결과

위와 같은 시스템 설계를 바탕으로 시스템을 구현을 위한 학습환경과 선별, 비선별된 데이터 학습 및 검증에 대해 살펴본다.

##### 1. 학습환경

표 3은 해양 침적 쓰레기 감지를 위한 모델의 YOLO 학습 테스트 설계 구현을 위한 컴퓨터 사양이다. CPU는 AMD사의 Ryzen 7 5800X- 8Core Processor 3.80 GHz, RAM은 8GB, 그래픽 카드는 NVIDIA사의 GeForce

표 3. 딥러닝 학습 환경  
Table 3. Deep Learning Environment

Environment	Name
CPU	AMD Ryzen 7 5800X- 8Core Processor 3.80GHz
RAM	8GB
GPU	NVIDIA GeForce RTX 3060
OS	Window 10 Pro
CUDA	v11.3
CuDNN	v8.2.1
Pytorch	1.8.1

표 4. 학습 Case 매개변수 분류표  
Table 4. Classification of learning case parameters

Learning Case	YOLOv5 model	Batch size	Epochs	image size
1	Xlarge	16	300	416
2	Large	16	300	
3	Medium	16	300	
4	Medium	64	300	
5	Small	16	300	
6	Small	16	1200	
7	Small	64	300	

표 5. 데이터 선별된 학습 Case 별 검증 테이블  
Table 5. Learning Verification Table of data screened cases

Learning Case	Thresh old (T)	TP detection amount	rope	fish net	cir trap	rec trap	eel trap	tire	none class	mAP
			AP							
1	0.7	0.52	0.46	0.38	0.67	0.13	0.67	0.78	0.57	3.66
2		0.61	0.69	0.42	0.7	0.13	0.5	0.72	0.71	3.87
<b>3 (BestCase)</b>		<b>0.67</b>	<b>0.75</b>	<b>0.54</b>	<b>0.78</b>	<b>0.19</b>	<b>0.5</b>	<b>0.83</b>	<b>0.43</b>	<b>4.02</b>
4		0.58	0.59	0.38	0.78	0.13	0.17	0.83	0.57	3.45
5		0.44	0.27	0.33	0.59	0.31	0.5	0.72	0.43	3.15
6		0.5	0.36	0.38	0.7	0.31	0.33	0.78	0.57	3.43
7		0.43	0.37	0.25	0.52	0.06	0.33	0.75	0.57	2.85

3060, 운영체제는 Window 10 Pro를 사용하였고 CUDA는 11.3 버전, CuDNN은 8.2.1 버전, PyTorch는 CUDA 버전에 맞는 1.8버전을 설치하여 학습환경을 구축했다.

##### 2. 선별된 데이터 학습 및 검증

테스트 설계에 적합한 구현을 위해서 다양한 모델을 이용해 학습하여 가장 성능이 좋은 모델을 가진 Best Case를 찾고자 했다.

데이터 학습은 Batch size, Epochs, Image size를 나누어 표 4의 7가지 경우로 진행했다. 검증 과정에서 실시간 감지 시스템에서의 성능을 위해 이미지가 아닌 해양 침적 쓰레기가 나오는 47분의 테스트 영상(mp4)에서 객체를 검출하여 검증작업을 했다. 실험과정에서 임계값(T)을 0.5로 지정하였지만, 다른 객체를 특정 클래스로 인식하는 것처럼 오탐률이 높게 나왔다. 본 논문에서는 이러한 점들을 방지하기 위해서 임계값(T)을 0.7로 지정하여 높은 신뢰도를 얻고자 했다. 검증에 사용된 영상에서의 장면은 총 175개( rope 59개, fish\_net 24개, cir\_trap 27개, rec\_trap 16개, eel\_trap 6개, tire 36개, 클래스 외 장면 7개 )이다.

표 5는 데이터 선별된 학습 Case별 검증 테이블이다. 표 5의 학습 Case는 표 4의 각각의 파라미터들로 학습된 학습 Case들과 동일하다. 임계값(T)이 0.7 이상에서의 학습 Case별 TP(True Positive)와 각 클래스별 AP(Average precision), mAP(mean Average precision)을 통해 검증작업을 수행했다.

어류 및 폐어구가 아닌 객체인 none class는 비검출을 TP로 판단해서 AP를 계산했다. 검증 결과 학습 Case 중 가장 높은 TP 감지율과 mAP를 가진 Case 3을 Best Case로 지정했다.




그림 9. 데이터 선별된 학습 Case 별 검출 장면 예시 이미지  
 Figure 9. Example images of detection scenes for each learning case

표 6. 비선별 된 데이터 학습 Case에 대한 검증 테이블  
 Table 6. Learning verification table of Data unscreened case

Learning Case	Threshold (T)	TP detection amount	rope	fish net	fish trap	tire	none class	mAP
			AP					
Unscreened Case	0.7	0.61	0.58	0.38	0.76	0.69	0.29	2.7

그림 9는 데이터 선별된 학습 Case 별 검출 장면 예시 이미지들이다.

### 3. 비선별된 데이터 학습 및 검증

데이터 선별된 학습 Case들 중 Best Case는 ‘Case 3’이다. 데이터 선별을 통한 정확도 및 성능 개선을 위해 이전 연구에서의 데이터 비선별된 데이터 셋에 ‘Case 3’의 학습 파라미터( Model : Medium, Batch size : 16, Epochs : 300, Image size : 416 )를 동일하게 학습시켜 결과를 비교하고자 했다. 데이터 비선별된 Case의 학습 데이터는 9000개의 이미지들로 구성되어 있으며, 클래스 세분화를 통한 성능 비교를 위해 객체별로 rope, fish\_net, fish\_trap, tire 4개의 클래스로만 구성했다.

### 4. Best Case VS Unscreened Case

(데이터 선별과정과 클래스 세분화 결과 비교)

#### 1) 모델 성능

표 6은 비선별된 데이터 학습 Case에 대한 검증 테이블이다. 같은 신뢰도에서의 결과를 비교하기 위해 임계값(T)은 0.7로 동일한 값으로 설정했다. 학습을 시킨 결과를 동일한 테스트 영상(47분, rope 59개, fish\_net 24개, cir\_trap 27개, rec\_trap 16개, eel\_trap 6개, tire 36개, 클래스 외 장면 7개 )을 통해 객체를 검출하여 검증한 결과 비선별된 데이터 학습 Case의 TP 감지율은 0.61, mAP는 2.7로 나왔다.

표 7은 데이터 선별 및 클래스 세분화된 Best Case와 데이터 비선별 및 클래스 미세분화 Case의 모델 학습 모델 성능 테이블이다.

표 7. Best Case and Unscreened Case 학습 모델 성능 테이블

Table 7. Best Case and Unscreened Case learning model performance table

	Best Case	Unscreened Case
TP detection amount	0.67	0.61
mAP	4.02	2.7

TP detection amount의 경우 Best Case가 0.67, Unscreened Case가 0.61로 Best Case의 TP 검출량이 0.06 더 높다.

mAP의 경우 Best Case가 4.02, Unscreened Case가 2.7로 Best Case의 mAP가 1.32 높다. 표 7의 결과를 비교한 결과 학습 모델 성능은 Best Case가 더 높다.

### 2) 데이터 선별과정

rope, fish\_net, tire 클래스의 경우 클래스 세분화 하지 않고 객체 종류별 클래스를 할당했기 때문에 Best Case와 Unscreened Case의 데이터 선별과정 결과 비교가 가능하다. Best Case의 rope, fish\_net, tire 세 클래스 AP는 각각 0.75, 0.54, 0.83이고, Unscreened Case의 rope, fish\_net, tire 세 클래스 AP는 각각 0.58, 0.38, 0.69이다.

비교 결과, Best Case의 rope, fish\_net, tire AP가 각각 0.17, 0.16, 0.14 더 높다. 클래스로 지정되지 않은 객체인 none class 검출 결과 AP 경우 Best Case가 0.43, Unscreened Case가 0.29로 Best Case가 0.14 더 높다.

### 3) 클래스 세분화

테스트를 위해 사용한 영상(47분)에서 cir\_trap(원형 통발), rec\_trap(사각 통발), eel\_trap(장어 통발) 객체가 존재하는 장면은 각각 27개, 16개, 6개 총 49개이다. Best Case의 경우 객체의 특징 및 용도에 따른 클래스를

표 8. 클래스 세분화 성능 비교를 위한 통발 클래스 학습 결과

Table 8. Results of learning a traditional class to compare class segmentation performance

Class	Best Case			Unscreened Case
	cir_trap	rec_trap	eel_trap	fish_trap
AP	0.78	0.19	0.5	0.76
TP amount	21/27	3/16	3/6	37/49

세분화하여 딥러닝 학습을 진행하였고, Unscreened Case의 경우 객체의 종류별로만 클래스를 지정하여 딥러닝 학습을 진행했다.

표 8은 클래스 세분화 성능 비교를 위한 통발 클래스 학습 결과 테이블이다.

클래스 세분화하지 않은 Unscreened Case의 경우 fish\_trap 클래스의 AP가 0.76으로 클래스 세분화한 Best Case의 cir\_trap, rec\_trap, eel\_trap 클래스의 AP 평균인 0.49보다 0.27 더 높다. TP 검출량을 비교했을 때 Best Case의 TP 검출량은 27/49이다. Unscreened Case의 TP 검출량은 37/49로 클래스를 형태 및 용도에 따라 세분화하지 않았을 때의 TP 검출량이 0.21 더 높다.

## V. 결론

본 논문에서는 딥러닝 객체인식 모델인 YOLOv5를 기반으로 실시간 해양침적쓰레기 감지 시스템을 구현하고 성능에 따른 개선 방법에 관하여 설계하고 테스트를 수행하였다. 개선 방법으로 진행된 2가지 과정은 ‘데이터 선별’과 ‘클래스 세분화’로 적용 여부에 따라 결과를 비교했다. 먼저 데이터 선별과정 유무에 따른 학습 성능을 비교할 때는 클래스 중 rope, fish\_net, tire 클래스를 통하여 진행하였으며, 비선별된 학습 데이터셋 보다 선별된 학습 데이터셋의 학습된 가중치를 사용하였을 때 더 좋은 결과를 얻을 수 있었다. 다음으로 클래스 세분화에 따른 학습 성능을 비교할 때는 trap과 관련된 클래스를 통해 비교했다. 클래스 세분화가 수행되지 않은 fish\_trap 클래스의 mAP는 클래스를 세분화했을 때보다 포괄적으로 인식되었고, TP 검출량으로 확인 결과 세분화했을 때의 결과보다 더 좋은 결과를 얻을 수 있었다.

비선별된 데이터셋과 클래스가 세분화된 데이터셋의 학습된 가중치의 객체인식 결과보다 불필요한 데이터를 선별하거나 특징 및 용도에 따라 유사 항목을 세분화하지 않은 데이터셋의 학습된 가중치의 객체인식 결과는 해양침적쓰레기 인식에 개선된 결과를 보인다. 추후 유사 분야 및 객체 인식을 위한 데이터 학습 및 연구에 본 개선 방법을 활용할 예정이다.



## References

- [1] Y. J. Kim and S. M. Jeong, “Consideration on the Standing Stock of Marine Wastes” in *Journal of Korea Society of Waste Management*, Vol. 33, No. 6, pp. 598–605, Sep. 2016. (DOI : 10.9786/kswm.2016.33.6.598)
- [2] Marine Environment Information Portal, “The justice of marine waste.” Internet: <https://www.meis.go.kr/mli/intro/learn.do>, [Jan.5,2022]
- [3] KOEM, “The final report of 2020 National Constal Waste Monitoring.” Internet: <https://www.koem.or.kr/site/koem/ex/board/View.do?cbIdx=370&bcIdx=30182>, Apr.20,2021[Jan.5,2022]
- [4] Ministry of Oceans and Fisheries “The 1st Basic Plan for the Management of Marine Waste and Marine Pollution Deposits (2021–2030).” Internet: <https://www.mof.go.kr/article/view.do?articleKey=39282&boardKey=22&menuKey=851&currentPageNo=1>, Jun.30,2021[Jan.5,2022]
- [5] S. H. Kim, Y. S. Yang, J. H. Jeong, M. S. Song, D. H. Lee, M. B. Choi, S. H. Cha, C. H. Lee and H. S. Kim, “Verification on the Ghost Fishing by Derelict Fishing Gears through the Tank Experiments” in *Journal of Fishries and Marine Sciences Education*, Vol. 28, No. 5, pp. 1258–1265, Oct. 2016. (DOI : <https://doi.org/10.13000/JFMSE.2016.28.5.1258>)
- [6] S. D. Kim and W. S. Kang, “Distribution Characteristics and Cost Estimation of Collection and Treatment of Deposited Marine Debris in Coastal Fisheries around the Southwestern Islands of Korea” in *Journal of the Korea Society for Marine Environment & Energy*, pp. 330–336, Nov. 2012. (DOI : <https://doi.org/10.7846/JKOSMEE.2012.15.4.330>)
- [7] Y. J. Park, Y. R. Yeom and E. S. Choi, “The untold story surroundubg the sea pollution source, “Waste phrase.” Internet : [http://www.ohmynews.com/NWS\\_Web/View/at\\_pg.aspx?CNTN\\_CD=A0002794810](http://www.ohmynews.com/NWS_Web/View/at_pg.aspx?CNTN_CD=A0002794810), Dec.15,2021[Jan.6,2022]
- [8] S. Ren, K. He, R. Girshick and J. Sun, “Faster R–CNN: Towards Real–Time Object Detection with Region Proposal Networks”, in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 39, No. 6, pp. 1137–1149, June. 2017. (DOI : <https://doi.org/10.48550/arXiv.1506.01497>)
- [9] J. Redmon, S. Divvala, R. Girshick and A. Farhadi, “You Only Look Once: Unified, Real–Time Object Detection”, in 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 779–788, June. 2016. (DOI : <https://doi.org/10.48550/arXiv.1506.02640>)
- [10] Y. H. Lee and Y. S. Kim, “Comparison of CNN and YOLO for Object Detection”, in *Journal of the Semiconductor & Display Technology*, Vol. 19, No. 1, pp. 85–92, March. 2020.
- [11] Sánchez Hernández, Sergio & Romero, H & Morales, A. (2020). A review: Comparison of performance metrics of pretrained models for object detection using the TensorFlow framework. *IOP Conference Series: Materials Science and Engineering*. 844. 012024. (DOI : 10.1088/1757–899X/844/1/012024)
- [12] M. Tan, R. Pang, and Q. V. Le. “Efficientdet: Scalable and efficient object detection.” In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 10781–10790 Jul. 2020. (DOI : 10.1109/CVPR42600.2020.01079)
- [13] Ultralytics, “yolov5.” Internet: <https://github.com/ultralytics/yolov5>, Jan.26,2020 [Oct.27,2021]
- [14] NaeJoung Kwak and DongJu Kim, “A study on Detecting the Safety helmet wearing using YOLOv5–S model and transfer learning”, *International Journal of Advanced Culture Technology(IJACT)*, Vol. 10, No. 1, pp. 302–309, (2022) (DOI : <https://doi.org/10.17703/IJACT.2022.10.1.302>)
- [15] NaeJoung Kwak and DongJu Kim, “Study On Masked Face Detection And Recognition using transfer learning”, *International Journal of Advanced Culture Technology(IJACT)*, Vol. 10, No. 1, pp. 294–301, (2022) (DOI : <https://doi.org/10.17703/IJACT.2022.10.1.294>)
- [16] Gan Liu and Sang–Hyun Lee, “Municipal waste classification system design based on Faster–RCNN and YoloV4 mixed model”, *International Journal of Advanced Culture Technology(IJACT)*, Vol. 9, No. 3, pp. 305–314, (2021) (DOI : <https://doi.org/10.17703/IJACT.2021.9.3.305>)
- [17] A backup space for my memory, “Regarding the view,” Internet: <https://nangchobi.tistory.com/474>, June. 21, 2021 [Dec.2,2021]
- [18] T. S. Wang, S. Y. Oh, H. S. Lee, J. W. Jang and M. Y. Kim, “A Study on the A.I Detection Model of Marine Deposition Waste Using YOLOv5” in *Proceeding of the Korea Artificial–Intelligence Convergence Technology Society Vol. 1, No. 1, Pusan:PS*, pp. 55, Aug. 2021.

- [19]Korea Policy briefing Portal, “Measures to prevent damage to abandoned fishing areas, such as the Korea Coast Guard and ghost fisheries, etc” Internet : <https://www.korea.kr/news/pressReleaseView.do?newsId=156446503>, [April,14,2021]
- [20]AI hub, “The image of ocean sediment waste” Internet : <https://aihub.or.kr/aidata/30754>, Jun.18, 2020[Oct.27,2021]
- [21]J. H. Lee, Y. H. Kang and D. J. Moon “AI Data Construction for Submerged Marine Debris to Advance Marine Debris Management” in Journal of the Korea Society for Marine Environment & Energy, pp. 4-5, Oct. 2021
- [22]Haneda Osamu. (2007). Knot method. Korea: Jinsun Books.

※ 본 논문(저서)는 부산광역시 및 (재)부산인재평생교육진흥원의 BB21플러스 사업으로 지원된 연구임. 또한 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 지역지능화 혁신인재양성(Grand ICT연구센터) 사업의 연구결과로 수행되었음.  
(IITP-2022-2016-0-00318)