

## 3D 렌더링 및 딥러닝을 활용한 기뢰매몰률 측정

장민수, 하용훈\*  
국방대학교 국방과학학과

### 3D Rendering and Deep Learning-based Mine Burial Rate Measurement

Min-Su Jang, Yong-Hoon Ha\*  
Department of Defense Science, Korea National Defense University

**요약** 본 연구에서는 3D 렌더링과 딥러닝 기술을 활용해 기뢰 매몰률을 측정하는 방법을 개발하였다. 기뢰는 해군에게 큰 위협이 되며, 해저에 매몰될 경우 탐지하기 어렵다. 현장에서의 기뢰 매몰률 측정은 다양한 제약 조건과 비용이 발생하기 때문에 이를 대체할 효율적인 방법이 필요하다. 본 연구에서는 MDM-1 기뢰의 3D 렌더링 데이터 1,246개를 활용하여 딥러닝 모델인 YOLOv8s를 학습시켰으며, 이를 통해 mAP@0.5 수치는 0.995로 높은 정확도를 보였다. 추가로, 테스트 영상 20개를 활용하여 검증하였고, 이를 통해 평균 72.75%의 정확도를 달성하였다. 이 연구는 제한적인 데이터 상황에서도 3D 렌더링과 딥러닝을 활용한 기뢰 매몰률 측정의 가능성을 보여주며, AUV와 결합한 기뢰 탐지에 활용될 수 있는 기초 연구로서 의미가 있다.

**Abstract** In this study, we developed a method to measure mine burial rates using 3D rendering and deep learning. Mines pose a significant threat to the navy and are difficult to detect when buried in the seabed. Since the in-situ measurement of mine burial rates is subject to various constraints and costs, an efficient alternative method is needed. For this purpose, we trained a YOLOv8s deep learning model using 1,246 3D rendering images of an MDM-1 mine and achieved a high accuracy with an mAP@0.5 score of 0.995. Additionally, we validated it using 20 test videos and achieved an average accuracy of 72.75%. This study shows the possibility of measuring mine burial rates using 3D rendering and deep learning, even with limited data. The study is meaningful as basic research that could be used for mine detection combined with an AUV.

**Keywords** : Mine, Burial Rate, AUV, 3D Rendering, Deep Learning, Object Detection, YOLO, Accuracy

#### 1. 서론

기뢰는 해저에 부설되어 함정의 접촉 또는 자기나 음향 신호 등에 감응하여 적의 함정을 파괴하는 해양 무기 체계이다. 기뢰는 폭발 시 함정에 막대한 손상을 줄 뿐 아니라, 기뢰를 제거하는 데에도 많은 시간과 노력이 필요하다. 함정의 자유로운 기동을 효과적으로 제한할 수 있다[1]. 기뢰가 부설되어 해저면에 파묻히는 정도를 기

뢰매몰률이라고 하며, 해저에 침전되어 있는 모래, 펄 등 해저저질, 해저면의 형태와 조류에 따라 다르게 나타난다. 기뢰매몰률은 처음에 기뢰가 투하되어 낙하하는 메커니즘에 영향을 받아 해저의 저질 특성과 해저에 가하는 충격 등으로 파묻히는 초기 매몰률이 있으며, 부설 이후 해저지형, 해저저질 특성, 해·조류 등 해양환경의 영향을 받아 추가적으로 파묻히는 후기 매몰률로 구분된다 [2].

\*Corresponding Author : Yong-Hoon Ha(Korea National Defense Univ.)

email: yonghoonha@korea.kr

Received September 8, 2023

Accepted December 8, 2023

Revised October 4, 2023

Published December 31, 2023

우리 해군은 이러한 기뢰매몰물을 측정하기 위해 2004년부터 'Q-Route 해양환경조사'의 일환으로 기뢰매몰물 측정을 수행하고 있다. Q-Route는 최단소해항로로써 동 사업은 전시에 북한의 공격 기뢰 부설에 대비하여 주요 항구의 Q-Route와 동남해역 해상교통로를 대상으로 기뢰전을 수행하는데 필요한 해양환경을 조사하는 것이다. 그러나 실제 해상에서 수행되는 기뢰매몰물 측정은 수백 kg 이상의 기뢰를 해저면에 투하하고 잠수부를 투입하기 때문에 하루에 1~2회로 제한되었고, 그나마도 기상 여건이 좋은 조건에서만 관찰이 가능하였기 때문에 실제로는 해저퇴적물의 전단강도 등을 이용하여 단순 경험식으로 산출된 부정확한 기뢰매몰물을 작전에 활용하였다[3]. 또한, 역학 모델을 이용한 기뢰매몰물 산출 방법이 있는데, 이를 위해서는 정확한 해양환경 변수(해저저질, 해·조류, 지형 등) 입력이 필수적이다. 따라서 정확한 기뢰매몰물을 얻기 위한 가장 확실한 방법은 직접적인 관측이나 주요 항만의 수와 매년 변화하는 해양환경을 고려하면 많은 예산과 시간이 요구될 수밖에 없다.

현재 우리 해군의 기뢰전 부대는 자율무인잠수정(AUV: Autonomous Underwater Vehicle, 이하 AUV)을 도입하여 운영 중이며, 소해작전에서의 활용 폭을 넓혀가고 있다. 특히, 자율운항제어, 수중복합항법, 장애물 회피 및 자동 기뢰탐지/식별 기술 등 인공지능 기술을 접목하여 정확하고 효과적으로 임무를 수행할 수 있는 방안을 모색하고 있다[4]. 앞서 설명했듯이 현재 기뢰매몰물 측정은 잠수부를 직접 투입하기 때문에 수심과 기상 여건에 제한사항이 많이 따른다. 그러므로 AUV는 이러한 제한사항을 극복할 수 있는 최상의 방법이 될 것이다. AUV는 사전 입력된 기동로에 따라 원하는 수심에서 이동하며, 해저에 위치한 기뢰에 대해 영상정보를 수집할 수 있다. AUV가 수집한 영상정보를 인공지능과 접목시키면 더욱 빠르고 정확한 기뢰매몰물 측정 방법이 될 것이다.

이번 연구의 목적은 AUV의 영상정보 수집을 고려하여 해저에 매몰된 기뢰 이미지를 3D 렌더링하고, 딥러닝 기법을 적용하여 기뢰매몰물을 측정하는 것이다. 2장에서는 기뢰와 기뢰매몰물의 정의 및 분류와 함께 관련 연구를 설명하며, 3장은 데이터 확보가 제한된 기뢰 이미지를 3D 렌더링으로 생성하고, YOLOv8을 활용한 기뢰매몰물 측정 모델 구성과 평가지표를 제시한다. 4장은 기뢰매몰물 측정 모델의 훈련과 실험결과를 평가하고, 5장에서는 연구의 최종 결론을 도출한다. 이번 연구의 전체적인 흐름은 Fig. 1과 같다.

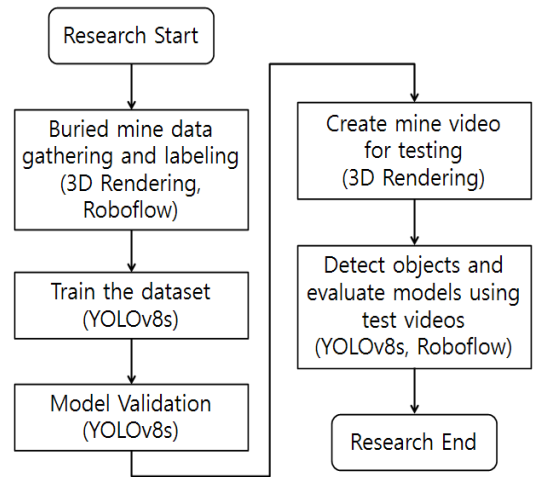


Fig. 1. Research Flow

## 2. 기뢰와 기뢰매몰물

### 2.1 기뢰의 가치와 분류

기뢰는 재래식 무기이면서 전략무기로 분류될 수 있는데, 항만이나 해역에 적 기뢰가 부설되면 아군 해상전력에 대한 직접적인 위협이 됨은 물론이며, 기뢰에 대한 위협효과를 제거 또는 최소화하기 위해 많은 시간과 위험이 뒤따른다. 그래서 적의 해상전력을 항만 내에 봉쇄할 때 가장 효과적인 무기체계 중 하나이다. 현재 기뢰는 대기뢰전 세력에 대한 대응능력과 표적 선별능력을 가진 지능기뢰와 함께 자체 추진능력을 갖거나 표적 추적과 파괴 기능을 갖는 능동기뢰로 발전하고 있다[5].

세계 각국에서 운용 중인 기뢰는 발화방식, 부설위치, 부설수단에 따라 분류할 수 있다. 발화방식에 따라 해안 통제소에 유선으로 연결되어 조종되는 조종기뢰, 선체와 직접 접촉하여 발화하는 접촉기뢰와 선박의 통과에 따른 물리적 변화를 원격 감지하여 발화하는 감응기뢰가 있다. 부설위치에 따라 해저에 가라앉아 위치가 고정되는 해저기뢰, 주 몸체는 수면 하의 일정한 수심에 위치하고 계류색으로 연결되어 닻으로 해저에 고정되는 계류기뢰와 수면 근처에서 조류를 따라 떠다니는 부류기뢰가 있으며, 부설수단에 따라 수상함, 잠수함, 항공기 부설용 기뢰로 분류할 수 있다.

### 2.2 기뢰매몰물

기뢰매몰물은 기뢰가 해저퇴적물에 얼마나 묻혔는지

나타내는 정량적인 비율로 기뢰의 전체 부피 대비 해저 퇴적물에 묻힌 부피를 백분율로 계산한 값이다. 기뢰가 매몰되는 시점에 따라 초기 매몰률과 후기 매몰률로 구분하며, 초기 매몰률은 기뢰의 해저면 낙하 시점의 속도와 자세, 기뢰형상 등의 영향을 받고, 후기 매몰률은 해양환경, 기뢰크기, 기뢰무게, 기뢰형상 등의 영향을 받는다. 서해와 같이 빨리 이루어진 퇴적물을 가진 해저면에서는 초기 매몰률이 높게 나타나며, 동해와 남해와 같이 모래나 자갈로 이루어진 해저면에서는 초기 매몰률이 낮게 나타난다. 이후 조류의 영향으로 인해 점차 기뢰의 후기 매몰률이 증가할 수 있다[6].

이번 연구에서는 우리나라 해역에 부설된 적의 해저기뢰를 고려하여 기뢰매몰률 측정 방법에 대해 실험을 진행한다. 해저기뢰는 기뢰매몰률이 발생하는 대표적인 기뢰이며, 우리나라의 해양 특성상 모래 혹은 펄 지역에서 조류로 인해 해저기뢰가 매몰되기 쉽다. 따라서 탐색과 제거가 어려워 부설 노력에 비해 더 많은 대응 노력을 강요하며 심리적인 효과가 큰 특징이 있다.

기뢰매몰률과 관련된 연구는 대부분 기뢰가 수중과 해저에서 역학적으로 매몰되는 메커니즘을 다룬다. Andrei V. Abelev et al.[7]은 기뢰가 수중으로 자유 낙하하는 동안의 실험 데이터를 수집하여 낙하할 때 기뢰의 움직임이 초기 매몰률에 어떠한 영향을 끼치는지 실험하였다. John Bradley et al.[8]은 다양한 센서를 장착한 기뢰를 사용하여 투하했을 때 매몰률을 측정하는 실험을 하였으며, 기뢰에 장착된 센서를 통해 부설된 기뢰가 해저면의 해·조류로 인하여 주변의 퇴적물의 영향으로 초기에 비해 얼마나 더 매몰되는지 실험하였다. 또한, Monica L. Wolfson et al.[9]은 미국 해군 연구소가 지원하는 기뢰 매몰의 실험 결과를 분석하였다. 3개의 쿼드포드와 5개의 삼각대를 기뢰 근처에 배치하여 2개월 동안 기뢰와 해저의 해류간 상호작용에 대해 분석한 결과 해저의 파동 에너지가 증가하면 매몰되는 양이 증가하는 것을 확인하였고, 해저에 덜 파묻힌 기뢰는 주변에 ripple이 형성되어 낮은 매몰률을 관찰할 수 있었다. Stéphane Guyonic et al.[10]은 매몰 기록 기뢰(BRMs: Burial recording mines, 이하 BRMs)를 이용하여 15분 간격으로 기뢰의 매몰을 측정하였다. 유체역학적인 조건과 퇴적물 특성에 대한 기뢰 매몰의 연관성을 분석하였다. 이 실험에서는 수중 음파 탐지기를 사용하여 기뢰의 매몰 과정을 관찰하였으며, 이를 통해 기뢰의 매몰은 안정적인 지역보다 국지적인 폭풍과 상당한 해파

가 발생하는 지역에서 활발하게 관찰되었고, 기뢰 주변에서 퇴적과 침식이 고르게 일어날수록 높은 수준의 기뢰 매몰이 발생한다고 분석하였다.

### 3. 기뢰매몰률 측정 실험 구성

본 연구는 실제 실험이나 역학적 계산을 통한 기뢰매몰률 연구와는 달리 미래의 AUV 운용을 대비하여 인공지능을 적용한 기뢰매몰률 측정에 대한 연구이다. 연구에서의 기뢰매몰률 측정 모델은 다음과 같다.

#### 3.1 데이터 구성 및 3D 렌더링

1장에서 언급했듯이 기뢰는 적으로 하여금 전진이나 해양을 통한 병력과 물자이동 등의 작전을 거부하고 시도할 경우 심각한 손실과 위협을 강요하는 무기체계이다[11]. 이러한 기뢰에 대한 정보는 전 세계적으로 각국이 비밀로 관리하고 있다. 따라서 기뢰에 대한 자세한 정보는 물론이며, 부설된 기뢰의 사진도 찾기 힘들다. 본 연구에서는 이러한 상황을 극복하고자 3D 렌더링을 이용하여 실제와 유사한 기뢰 매몰 데이터를 생성하였다. 3D 렌더링은 3차원 객체를 2차원 디스플레이에 사실적으로 입체감있게 보여주는 기법으로 본 연구에서는 블렌더(Blender, 이하 “블렌더”)를 사용하였다. 3D 렌더링의 기술은 Modeling, Texturing, Rendering 단계로 이루어진다. Modeling은 생성할 객체의 비슷한 크기와 형태로 조절하며, Texturing은 모델링한 객체에 색상과 재질을 추가하여 표면을 구현하고, 사실적인 광원의 방향과 세기를 설정하여 실제 환경과 유사하게 표현한다. Rendering은 사용자가 지정한 관점에서의 장면을 단일 이미지로 생성하거나 여러 프레임을 연속으로 렌더링하여 영상으로 생성할 수 있다.

데이터를 생성하기에 앞서 모델링을 할 대상으로 세계 최고의 기뢰 보유국 중 하나이며, 북한과도 연관이 있는 러시아의 MDM-1 기뢰로 설정하였다. MDM-1 기뢰는 수상함뿐만 아니라 잠수함에서도 부설 가능한 기뢰이며, 후속 모델이 MDM-2~5까지 다양하게 개발되고 있는 대표적인 해저기뢰다. 특히, 해당 형태의 기뢰는 전시에 잠수함을 통해 우리의 주요 항만에 부설될 수 있는 가장 위협적인 기뢰로써 형상과 제원은 Fig. 2와 Table 1과 같다[12].



Fig. 2. Shape of MDM-1 mine

Table 1. Specifications of MDM-1 mine

Contents	Specifications
Diameter [mm]	534
Length [mm]	2860
Weight [kg]	960
Operating depth [m]	8 ~ 120

전체적인 데이터는 러시아의 MDM-1 기뢰를 모델링하여 3차원의 Z축을 기준으로 기뢰의 전체적인 면적이 전부 보일 때를 매몰률 0%로 하고, 기뢰의 면적이 해저면에 완전히 매몰된 상태를 매몰률 100%로 가정하여 0%에서 90%까지 10% 단위로 설정하였다. 우리나라의 동해, 서해, 남해의 다양한 해저면을 조성하기 위해 모래와 펄 재질의 해저 저질을 구성하고, 주간과 야간 시간대

해저의 시야를 고려하여 조명의 색상을 설정하였다. 실제 AUV가 기뢰를 탐지할 때 여러 각도에서 기동하는 것을 고려하여 기뢰의 전면, 후면, 양옆, 대각선 방향의 데이터를 생성하였고, 최종적으로 생성한 데이터는 총 1,246개이다.

생성한 데이터는 딥러닝 모델을 훈련시킬 수 있는 플랫폼인 Roboflow를 이용하여 Bounding Box와 각 매몰률에 대해 0%에서 90%까지 10% 간격으로 클래스를 부여하여 레이블링했으며, Fig. 3은 3D 모델링을 이용하여 생성한 데이터에 레이블링한 예시를 보여준다.

### 3.2 모델 구성

기뢰매몰률 측정 모델에 적용한 객체탐지 알고리즘은 YOLOv8을 활용하였다. YOLO는 실시간 객체 탐지 알고리즘 중 빠른 처리 속도와 정확성이 좋아 이미지에서 객체를 빠르고 안정적으로 식별할 수 있는 기법이다[13]. YOLO는 객체의 위치검출과 객체분류를 한번에 실행하는 1단계 객체인식 방식을 사용하고 있어, 2단계 객체인식 모델과 비교했을 때 정확도는 거의 비슷하나 속도가 매우 빠르다는 장점이 있다. 2016년에 YOLOv1이 공개된 이후 지속적으로 업데이트해 왔으며, 최근 2023년 1월에 YOLOv8이 공개되었다.




Fig. 3. Labeling of train datasets

YOLOv8은 Backbone, Neck, Head로 구성되어 있으며, Backbone은 입력데이터로부터 다양한 Feature Map을 추출하고, Neck은 Backbone과 Head를 연결하는 중간 구성요소로서 Backbone에 의해 추출된 특징들을 종합하는 역할을 수행한다. Head는 Backbone과 Neck에 의해 생성된 특징에 기초하여 객체의 위치검출과 객체분류를 동시에 예측하는 1단계 객체인식 방식을 수행하여 연산속도가 매우 빠르다는 장점이 있다. 또한, YOLOv8은 Anchor-Free Model이라는 특징이 있다. 기존의 YOLO 모델은 여러 개의 예측될 법한 Bounding Box의 Anchor값들을 기준으로 예측을 수행한 반면, YOLOv8은 기본 입력된 Anchor값을 사용하지 않고 객체의 Center를 직접 예측하기 때문에 커스텀 데이터를 학습하기에 효과적이고, 이전 버전의 YOLOv5와 비교했을 때 더 높은 탐지성능을 갖고 있다[14].

YOLOv8은 네트워크의 크기에 따라 YOLOv8n (nano), YOLOv8s(small), YOLOv8m(medium), YOLOv8l (large), YOLOv8x(extra large)의 5가지 모델로 분류하며, 크기가 커질수록 속도는 느리나 정확도가 높은 특징이 있고, 반대로 크기가 작을수록 비교적 정확도는 낮으나 속도가 빠른 특징이 있다. 본 연구에서는 영상에서의 실시간 객체탐지를 위해 비교적 낮은 정확도를 보이지만 빠른 연산속도를 보여주는 YOLOv8s를 적용하였다[15].

3.1절에서 언급했듯이 학습 데이터셋은 총 1,246개이며, 기뢰매몰률 측정 모델의 훈련과 검증데이터를 8:2 비율로 학습을 진행하였고, batch size 16, image size 640, epoch 500으로 설정하여 학습을 실행하였다. 모델 학습은 Windows 11, Intel(r) Core(TM) i7-1165G7 CPU와 구글 Colaboratory Pro에서 제공하는 GPU의 환경에서 실시하였다. 구글 Colaboratory Pro의 GPU에 대한 상세한 환경은 Table 2와 같다.

Table 2. Environment of Google Colaboratory Pro

GPU	RAM	Python ver.	CUDA ver.
A100	83.5GB	3.10.12	12.0

### 3.3 모델 평가지표

모델의 객체탐지 성능을 평가하기 위해 혼동행렬 (Confusion Matrix)을 이용하여 정밀도(Precision), 재현율(Recall), F1-Score와 mAP(mean Average Precision)의 값을 사용한다. 혼동행렬은 Table 3과 같

이 실제 정답과 모델이 예측한 결과에 대한 교차표이다. 혼동행렬에서 실제 Positive인 값을 모델이 Positive라고 올바르게 예측한 경우를 True Positive(이하 TP), 실제 Positive한 값을 모델이 Negative라고 잘못 예측한 경우를 False Negative(이하 FN), 실제 Negative한 값을 모델이 Positive라고 잘못 예측한 경우를 False Positive(이하 FP), 실제 Negative한 값을 모델이 Negative라고 올바르게 예측한 경우를 True Negative(이하 TN)이다[16].

Table 3. Confusion Matrix

		Predicted Class	
		Positive	Negative
True Class	Positive	True Positive	False Negative
	Negative	False Positive	True Negative

정밀도는 모델이 Positive라고 예측한 샘플 중에서 실제로 정답이 Positive인 비율이며, 재현율은 실제로 정답이 Positive라고 할 때 모델도 Positive로 예측한 비율이다. F1-Score는 정밀도와 재현율의 조화 평균을 이용한 값으로 모델의 데이터가 불균형할 때, 모델의 예측 능력을 확인하기 위해 사용하며, 수치가 높을수록 모델의 성능이 더 좋은 것임을 알 수 있다. 위 3개의 평가지표 계산은 Eq. (1)~(3)과 같다[17].

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

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

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

mAP는 실제 객체가 탐지된 재현율의 변화에 따른 정밀도의 값을 평균한 값이다. mAP는 높으면 높을수록 모델의 성능이 우수하다는 것을 의미하며, 주로 IoU(Intersection over Union) 값을 사용한다. IoU는 실제 이미지에서 해당 객체 정보를 나타내는 부분인 Ground-Truth bounding box와 객체 탐지 모델이 예측한 부분인 Predicted bounding box가 겹치는 비율을 의미하며, 이는 Eq. (4)와 같다[18].

$$IoU = \frac{area(Ground\ Truth \cap Predicted)}{area(Ground\ Truth \cup Predicted)} \quad (4)$$

보통 IoU가 0.5 이상인 경우를 평가지표를 삼아서 mAP@0.5를 주로 사용하며, 이는 IoU가 0.5 이상인 경우만 True Positive로 본다는 의미이다. 따라서 mAP@0.5 값이 높을수록 성능이 좋은 모델임을 나타낸다[19].

## 4. 결과 분석

### 4.1 모델 학습 결과

3.3절에서 언급한 평가지표에 따라 학습 모델의 성능을 epoch별로 기록하여 Table 4와 같이 비교하였다. 총 500회의 epoch 중 epoch 311에서 최적의 결과가 도출되었으며, epoch 360 이후에는 성능이 나아지지 않는 과적합이 이루어지면서 학습이 중단되었다. 따라서 학습된 모델에 대한 평가는 최적의 결과를 도출한 epoch 311의 가중치를 이용하여 실험을 진행하였다.

Table 4. Results of trained model

Epoch	Precision	Recall	F1-Score	mAP@0.5
50	0.893	0.92	0.906	0.902
100	0.97	0.978	0.974	0.959
200	0.981	0.973	0.977	0.972
<b>311</b>	<b>0.986</b>	<b>0.995</b>	<b>0.990</b>	<b>0.995</b>
360	0.993	0.99	0.991	0.98

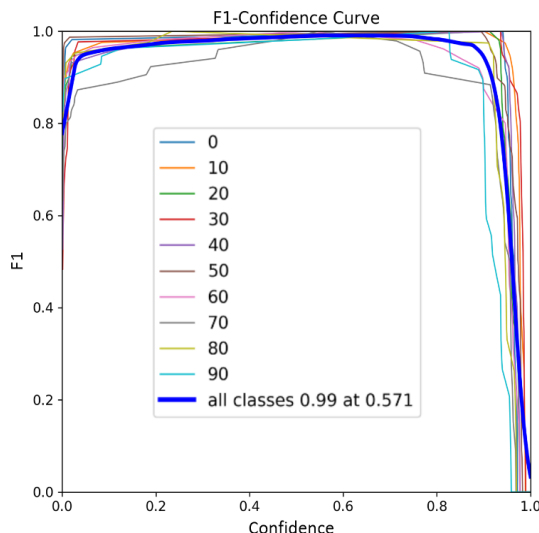


Fig. 4. Graph of F1-score results

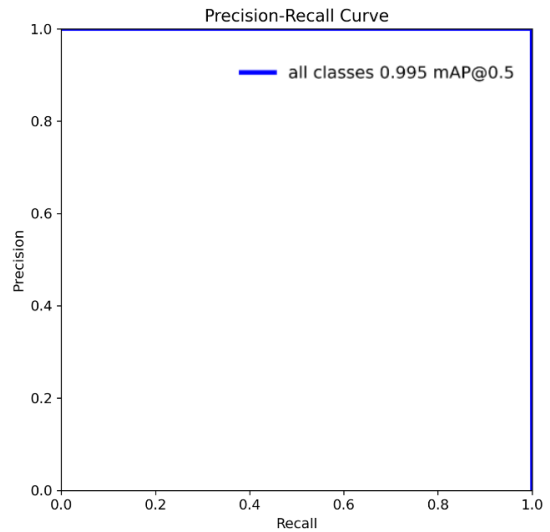


Fig. 5. Graph of mAP@0.5 result

Fig. 4와 Fig. 5는 데이터셋의 학습이 잘 이루어졌음을 확인하기 위해 그래프로 제시하였다. Fig. 4는 F1-Score의 지표를 나타낸 것으로 그래프에서 곡선 아래의 면적이 넓을수록 성능이 좋은 모델임을 나타낸다. Fig. 5는 모델의 성능을 평가하는 방법 중 하나인 PR Curve 그래프이며, 곡선 아래의 면적은 mAP@0.5값을 나타내어 면적이 넓을수록 mAP@0.5 값이 높아 모델의 성능이 우수한 것을 의미한다[20]. 전체적인 클래스의 mAP@0.5가 0.995로 학습이 잘 이루어졌음을 확인할 수 있다.

### 4.2 모델 평가 방법

기뢰매몰물 측정 모델을 평가하기 위해 블렌더 프로그램을 이용하여 매물물별로 테스트 영상을 생성하였다. 테스트 영상은 AUV의 광학카메라가 흑백 화질인 것을 고려하였으며, 모래 환경과 펄 환경의 흑백 영상을 각 10개(0%~90%)씩 생성하여 총 20개의 영상을 평가하였다. 평가는 테스트 영상 속의 AUV가 매몰된 기뢰를 탐지하여 그 주위를 360° 맴돌면서 어느 수치의 매물물을 탐지하는지 식별하는 방법으로 진행하였다.

최종적인 평가는 테스트 영상의 전체 프레임을 1프레임 간격으로 구분하여 각 프레임마다 모델이 탐지하는 모든 매물물을 추출하여 정확도를 계산하였다. 정확도 계산은 Eq. (5)와 같으며, Fig. 6은 모델이 테스트 영상에서 기뢰의 매물물을 식별하는 예시를 보여준다.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$




Fig. 6. Example of mine burial rate measurement

### 4.3 실험 결과

본 연구의 기뢰매몰률 측정 모델은 100프레임의 테스트 영상을 이용하여 총 20번의 평가를 진행하였으며, 모델이 측정한 기뢰매몰률의 정확도는 Table 5와 같다.

모래 환경의 #1에서는 매몰률 0% 97회, 10% 3회를 식별하여 정확도 97%로 전체 실험 중 가장 높은 정확도를 측정하였다. #2는 매몰률 10% 89회, 20% 11회를 식별하여 정확도 89%로 기뢰매몰률이 낮은 상황에서 측정이 잘 이루어짐을 확인하였다. #3부터 #7까지는 74~81%의 정확도를 보였으나, #4부터 모델이 기뢰매몰률을 측정하지 못하는 상황이 발생하였다. #8은 매몰률 60% 9회, 70% 71회, 80% 8회, 미측정 12회로 정확도 71%를 보여 정확도가 감소하고, 미측정 횟수가 증가한 것을 확인하였다. #9와 #10에서의 정확도는 각 67%와 62%를 측정하여 매몰률이 증가할수록 정확도가 감소한 것을 확인하였고, 미측정 횟수는 #9에서 25회, #10에서

36회로 지속 증가한 것을 확인하였다. 이는 기뢰가 해저에 매몰될수록 모델이 기뢰와 해저면의 경계면을 구분하는 것이 어려워 기뢰매몰률을 미측정하는 횟수가 증가한 것임을 확인하였다.

별 환경의 #11에서 매몰률 0% 80회, 10% 12회, 미측정 8회로 80%의 정확도를 보여 별 환경의 실험 중 가장 높은 정확도를 기록하였으나, 모래 환경에서의 실험과는 달리 기뢰매몰률을 측정하지 못하는 상황이 발생하였음을 확인하였다. #12부터 #17까지는 67~71%의 정확도를 측정하였으며, 기뢰매몰률을 미측정하는 상황이 증가하고 있음을 확인하였다. #18은 매몰률 60% 16회, 70% 63회, 미측정 21회로 정확도 63%를 보였으며, 모래 환경에서의 실험과 같은 이유로 정확도는 감소하고, 미측정 횟수는 증가하였다. #19와 #20은 각 62%, 60%의 정확도를 측정하여 지속 감소하였으며, 미측정 횟수는 각 23회와 29회로 증가하였다. 모델은 전체적으로 60% 이상의 정확도를 보여주고 있으며, 평균적으로 계산했을 시 72.75% 수준의 정확도를 도출하였다. 실제 해상에서 실시하는 기뢰매몰률 측정은 해저 등급에 따라 총 4개의 등급(0~10%, 10~20%, 20~75%, 75% 이상)으로 분류하고 있다. 이번 연구에서는 기뢰매몰률을 4개의 등급으로 분류한 방식이 아닌 10% 단위로 식별하여 기존의 방식보다 더 세밀한 측정 방법을 통해 결과를 도출하였으며, 의미있는 수준의 정확도를 확인할 수 있었다.

Table 5. Accuracy of model

Tests for sandy sediment										
Test number	#1	#2	#3	#4	#5	#6	#7	#8	#9	#10
Real burial rate	0	10	20	30	40	50	60	70	80	90
Number of times detected	0% : 97 10% : 3	10% : 89 20% : 11	10% : 1 20% : 78 30% : 21	20% : 3 30% : 80 40% : 15 None : 2	30% : 15 40% : 81 50% : 1 None : 3	40% : 12 50% : 80 60% : 3 None : 5	50% : 12 60% : 74 70% : 9 None : 5	60% : 9 70% : 71 80% : 8 None : 12	70% : 6 80% : 67 90% : 2 None : 25	80% : 2 90% : 62 None : 36
Accuracy of Predicted burial rate	97%	89%	78%	80%	81%	80%	74%	71%	67%	62%
Tests for muddy sediment										
Test number	#11	#12	#13	#14	#15	#16	#17	#18	#19	#20
Real burial rate	0	10	20	30	40	50	60	70	80	90
Number of times detected	0% : 80 10% : 12 None : 8	10% : 70 20% : 20 None : 10	10% : 2 20% : 67 30% : 19 None : 12	30% : 71 40% : 16 None : 13	40% : 67 50% : 19 None : 14	50% : 67 60% : 17 None : 16	60% : 69 70% : 14 None : 17	60% : 16 70% : 63 None : 21	80% : 62 90% : 15 None : 23	80% : 11 90% : 60 None : 29
Accuracy of Predicted burial rate	80%	70%	67%	71%	67%	67%	69%	63%	62%	60%

## 5. 결론

이번 연구에서는 3D 렌더링과 딥러닝을 이용하여 기뢰매몰률을 측정하였다. 기뢰는 함정에 물리적인 피해와 심리적인 피해까지 낼 수 있는 무기체계이며, 해저면에 매몰되면 식별이 어려워 대응하기에 큰 어려움이 있다. 실제 해상에서 수행하고 있는 기뢰매몰률 측정은 기상여건의 제한과 많은 예산과 시간을 요구하고 있어 이를 보완하고자 딥러닝 기법을 적용하여 기뢰매몰률을 측정하였다. 딥러닝 학습에 필요한 데이터는 러시아의 MDM-1 기뢰를 모델링하여 다양한 조건으로 매몰되어 있는 기뢰 이미지 총 1,246개를 생성하였고, 기뢰 매몰률 측정 모델은 mAP@0.5가 0.995로 학습이 잘 이루어졌음을 확인하였다.

테스트 영상은 실제 AUV가 흑백 영상임을 고려하여 흑백 영상으로 20개를 준비하였으며, 영상마다 1프레임 간격으로 모델이 탐지하는 매몰률을 추출하여 정확도를 계산하였다. 모델은 모든 테스트 영상에서 60% 이상의 정확도를 보여주고 있으며, 평균적으로 72.75%의 정확도를 나타내었다. 다만, 기뢰매몰률이 높아질수록 모델이 해저면과 기뢰를 구분하는 것이 어려워 기뢰매몰률을 미측정하는 횟수가 증가하였다. 이번 연구에서는 전면, 후면, 양옆, 45도의 대각선 방향에서의 모습으로 데이터를 구성하였다. 테스트 영상에서 확인한 결과로 기뢰매몰률이 낮을 때는 모델이 인지하는 전체적인 면적이 크기에 학습되지 않은 각도에서도 Confidence Score가 0.8 이상으로 높았으나, 기뢰매몰률이 높아질수록 모델이 인지하는 면적이 작아져 학습되지 않은 각도에서는 기뢰를 탐지하지 못하거나 Confidence Score가 0.5 이하로 낮은 것을 확인하였다. 이를 보완하기 위해 30도와 60도 등 더욱 세밀하고 다양한 각도에서 바라본 데이터를 준비하여 학습하는 것이 필요하다.

이번 연구는 실제 해상에서 시행하고 있는 방법과 비교하였을 때 4개의 등급이 아닌 10% 단위로 분류함으로써 더 세밀하게 측정하였으며, 인공지능을 접목시켜 의미있는 정확도로 기뢰매몰률을 측정할 수 있음을 확인하였다. 데이터 확보가 제한된 상황에서 3D 렌더링을 이용하여 데이터를 생성한 후 인공지능을 활용하여 충분히 기뢰매몰률 측정이 가능한 것을 제시하여 향후 기뢰매몰률 측정과 기뢰탐지 연구 시 참고가 될 수 있음에 본 연구의 결과는 충분한 의의가 있다.

본 연구의 제한사항으로 MDM-1 기뢰에 대해서만 모델링을 했기 때문에 다양한 데이터셋을 구성하지 못한

점과 실제 해상에서의 실험을 통해 모델의 안정성과 정확도에 대해 검증하지 못하여 추가적인 후속연구가 필요하다. 따라서 향후 후속 연구를 위해 MDM-1 기뢰에 국한된 상황이 아닌 더욱 다양한 모델링 대상과 테스트 영상을 선정할 필요가 있다. 또한, 군에서 보유 중인 실제 기뢰의 데이터를 활용할 수 있다면 더 정확하고 실질적인 결과를 도출할 수 있을 것이다. 본 연구는 해군 해양환경조사의 기뢰매몰률 측정과 더불어 기뢰전 부대의 전비태세 향상에도 기여할 수 있을 것으로 기대된다.

## References

- [1] S. G. Kim, J. J. Yoon, J. S. Kang, J. K. Kim, T. H. Kim, World of Naval weapon system, p.666, Hantee Media, 2016, pp.344.
- [2] Y. H. Ha, D. S. Kang, Y. S. Hwang, J. H. Kim, B. J. Ryu, Development of Mine Burial Rate Investigation Method/Verification Method, Research report, Korea National Defense University, Korea, pp.33.
- [3] Y. H. Ha, D. S. Kang, Y. S. Hwang, J. H. Kim, B. J. Ryu, Development of Mine Burial Rate Investigation Method/Verification Method, Research report, Korea National Defense University, Korea, pp.2-6.
- [4] J. S. Woo, J. Y. Kim, J. W. Moon, J. N. Seo, W. J. Sung, S. C. Yoo, B. H. Jeon, H. S. Choi, Autonomous Underwater Vehicle called an underwater drone, p.247, GS Inter Vision, 2020, pp.40-45.
- [5] S. G. Kim, J. J. Yoon, J. S. Kang, J. K. Kim, T. H. Kim, World of Naval weapon system, p.666, Hantee Media, 2016, pp.411-414.
- [6] Y. H. Ha, D. S. Kang, Y. S. Hwang, J. H. Kim, B. J. Ryu, Development of Mine Burial Rate Investigation Method/Verification Method, Research report, Korea National Defense University, Korea, pp.15.
- [7] Andrei V. Abelev, Philip J. Valent, K. Todd Holland, "Behavior of a Large Cylinder in Free-Fall Through Water", *IEEE JOURNAL OF OCEANIC ENGINEERING*, Vol.32, No.1, pp.10-20, Jan. 2007. DOI: <http://dx.doi.org/10.1109/JOE.2007.890938>
- [8] John Bradley, Sean Griffin, Maurice Thiele, Jr., Michael D. Richardson, Peter D. Thorne, "An Acoustic-Instrumented Mine for Studying Subsequent Burial", *IEEE JOURNAL OF OCEANIC ENGINEERING*, Vol.32, No.1, pp.64-77, Jan. 2007. DOI: <http://dx.doi.org/10.1109/JOE.2007.890945>
- [9] Monica L. Wolfson, David F. Naar, Peter A. Howd, Stanley D. Locker, Brian T. Donahue, Carl T. Friedrichs, Arthur C. Trembanis, Michael D. Richardson, Thomas F. Wever, "Multibeam Observations of Mine




Burial Near Clearwater, FL, Including Comparisons to Predictions of Wave-Induced Burial”, *IEEE JOURNAL OF OCEANIC ENGINEERING*, Vol.32, No.1, pp.64-77, Jan. 2007.

DOI: <http://dx.doi.org/10.1109/JOE.2006.889317>

- [10] Stéphane Guyonic, Mathieu Mory, Thomas F. Wever, Fabrice Arduin, Thierry Garlan, “Full-Scale Mine Burial Experiments in Wave and Current Environments and Comparison With Models”, *IEEE JOURNAL OF OCEANIC ENGINEERING*, Vol.32, No.1, pp.64-77, Jan. 2007.  
DOI: <http://dx.doi.org/10.1109/JOE.2007.890951>
- [11] S. G. Kim, J. J. Yoon, J. S. Kang, J. K. Kim, T. H. Kim, World of Naval weapon system, p.666, Hantee Media, 2016, pp.413.
- [12] Russian Defence Export, Shape and Specifications of MDM-1 mine From: <http://roe.ru/eng/catalog/naval-systems/shipborne-weapons/mdm-1/> (accessed Jul 13, 2023.)
- [13] Juan R. Terven, Diana M. Cordova-Esparaza, “A Comprehensive Review of YOLO: From YOLOv1 and Beyond”, *arXiv preprint(arXiv:2304.00501v4)*, revised 2023.
- [14] S. Rath, YOLOv8 Ultralytics: State-of-the-Art YOLO Models, Available From : <https://learnopencv.com/ultralytics-yolov8/> (accessed Sep. 24, 2023)
- [15] G. Jocher, Ultralytics YOLOv8, Available From: <https://github.com/ultralytics/ultralytics> (accessed Sep. 24, 2023)
- [16] I. G. Cheon, Deep Learning Express, p.558, BookSR, 2021, pp.130.
- [17] Andreas C. Müller, Sarah Guido, Introduction to Machine Learning with Python(Second Edition), p.503, Hanbit Media, 2022, pp.375-406.
- [18] Rafael Padilla, Sergio L. Netto, Eduardo A. B. da Silva, “A Survey on Performance Metrics for Object-Detection Algorithms”, *IEEE International Conference on Systems, Signals and Image Precessing(ISWSIP)*, Jul. 2020.  
DOI: <http://dx.doi.org/10.1109/IWSSIP48289.2020.9145130>
- [19] Tsung-Yi Lin, Michael Maire, Serge Belongie, Lubomir Bourdev, Ross Girshick, James Hays, Pietro Perona, Deva Ramanan, C. Lawrence Zitnick, Piotr Dollár, “Microsoft COCO: Common Objects in Context”, *arXiv preprint(arXiv:1405.0312v3)*, revised 2015.
- [20] Stephen Marsland, Machine Learning: An Algorithmic Perspective(Second Edition), p.508, Jei Pub, 2016, pp.27-33.

장 민 수(Min-Su Jang)

[정회원]



- 2015년 2월 : 계명대학교 전자공학과 (전자공학사)
- 2022년 1월 ~ 현재 : 국방대학교 국방과학학과 무기체계전공 석사과정

<관심분야>

무기체계, 해양무인체계, 인공지능

하 용 훈(Yong-Hoon Ha)

[정회원]



- 1994년 2월 : 해군사관학교 해양학과 (이학사)
- 1997년 2월 : 서울대학교 해양학과 (이학사)
- 2000년 12월 : 미국 해군대학원 공학음향학 (공학석사)
- 2009년 2월 : 서울대학교 조선해양공학 (공학박사)
- 2019년 3월 ~ 현재 : 국방대학교 국방과학학과 부교수

<관심분야>

감시정찰무기체계, 표적탐지 및 추적, 수중음향 및 대잠전 관련 M&S 등