



Received: 2024/08/15  
Revised: 2024/08/30  
Accepted: 2024/09/25  
Published: 2024/09/30

**\*Corresponding Author:**

**Joonki Paik**  
Graduate School of Advanced Imaging Science,  
Multimedia & Film, Chung-Ang University  
84, Heukseok-ro 5-gil, Dongjak-gu, Seoul,  
Republic of Korea  
E-mail: paikj@cau.ac.kr

# Image Mix-up 기법과 YOLOv8을 활용한 Side Scan Sonar Image에서의 기뢰추정물 탐지 모델 개발

## Development of a Minelike Contacts Detection Model in Side Scan Sonar Images Using Image Mix-up and YOLOv8

임정규<sup>1</sup>, 박찬영<sup>2</sup>, 백준기<sup>3\*</sup>

<sup>1</sup>해군 중위/중앙대학교 국방 AI 교육대학 연수생  
<sup>2</sup>중앙대학교 첨단영상대학원 영상공학 박사과정  
<sup>3</sup>중앙대학교 첨단영상대학원 및 AI대학원 교수

Jeong-Kyu Lim<sup>1</sup>, Chanyeong Park<sup>2</sup>, Joonki Paik<sup>3\*</sup>

<sup>1</sup>LTJG, ROK Navy/Trainee, Defense AI Education College, Chung-Ang University  
<sup>2</sup>Ph.D. student, Major of AI Imaging, Graduate School of Advanced Imaging Science, Multimedia & Film, Chung-Ang University  
<sup>3</sup>Professor, Graduate School of Advanced Imaging Science, Multimedia & Film and AI Graduate School, Chung-Ang University

### Abstract

본 연구는 기뢰 탐색 절차 주요 장비인 Side Scan Sonar (S.S.S) 데이터 효율적인 증강을 목표로 한다. 해군의 기뢰 관련 국방데이터 부족 문제를 해결하기 위해 S.S.S. 데이터를 활용하여 연안 해저 환경 데이터와 image mix-up 기법으로 데이터를 증강 후, 비교군을 설정하여 실시간 객체 인식 모델 YOLOv8을 통해 실험을 진행한다. 그 결과, 합성데이터가 모델 성능을 유의미하게 향상시켰음을 확인했으며, 이는 해군 유무인 복합체계 내 기뢰 식별 데이터 부족에 대안을 제공했다는 그 의의가 있다.

In this paper, we aim to efficiently augment Side Scan Sonar (S.S.S.) data, a critical tool in mine detection operations. However, the scarcity of mine-related defense data available to the Navy presents a significant challenge. To solve this issue, we use overseas S.S.S. data, enhancing it with coastal seabed environmental data and the image Mix-up technique. We conducted experiments using the YOLOv8 real-time object detection model. The results indicate that the inclusion of synthetic data substantially enhances the model's performance. This finding is particularly noteworthy as it provides a viable solution to the shortage of mine classification data in the Navy's manned and unmanned teaming systems.

### Keywords

해저기뢰(Bottom Mine),  
측면주사음탐기(Side Scan Sonar),  
Image Mix-up, YOLOv8

### Acknowledgement

이 논문은 2024년도 정부(과학기술정보통신부) 재원으로 국방부 및 정보통신기획평가원(IITP)에 의한 AI대학원 프로그램(2021-0-01341, 인공지능대학원지원(중앙대학교))의 지원을 받아 수행되었습니다.

이 논문은 2024년도 정부(과학기술정보통신부)의 재원으로 한국연구재단(NRF, NRF-RS2024-00343863)의 지원을 받아 수행되었습니다.

## 1. 서론

국방부는 4차 산업혁명의 기술을 접목한 국방혁신 4.0을 추진 중이고, 해군은 그에 맞추어 해군 유·무인 복합체계를 지향하고 있다. 하지만 이를 실현할 국방 데이터의 부족이 지속적으로 문제가 되고 있으며, 특히 해군의 중요한 성분작전인 기뢰전 데이터는 더욱 부족하다. 본 연구는 이에 대응하여 양질의 해외 데이터셋과 연안 해저 환경 데이터와의 image mix-up 기법으로 데이터를 증강한 후 비교군을 나누어 실시간 객체 탐지 모델 실험을 진행하였다.

## 2. 기뢰전 일반 및 측면주사음탐기 소개

### 2.1. 전·평시 해군의 역할 및 기뢰전

전·평시 해군의 역할은 총 5가지로 구별되며, 그중 전·평시에 중요

성이 부각되는 역할은 ‘해상교통로(sea lane of communication, SLOC)의 보호’이다. SLOC은 전시 상황에서 합참 예하 전 부대의 전쟁 지속능력을 담당하는 전쟁 물자들의 운송을 담당한다. 특히 대한민국은 대부분의 수출입을 SLOC에 의지하고 있기에, 해군을 중심으로 다양한 관계 부처 네트워크 형성과 군사적 자산을 통해서 SLOC의 안전과 통행의 자유를 보장하고 있다.

이 SLOC를 위협하는 요소 중 가장 값싸고 효율적인 전략 병기로서 기뢰는 가장 유용한 수단으로 평가받는다. 국가는 이 군사적 자산을 이용해 타 국가의 SLOC를 방해하거나, 자신의 SLOC 안전을 보장한다. 현재 해군은 제5기뢰/상륙전단 내 제52기뢰전대를 통해서 다양한 기뢰 작전 관련 훈련을 실시하여 기뢰전 능력을 유지 및 향상하고 있다.

2.1.1 기뢰 종류 및 기뢰전 일반

기뢰란 수상함 혹은 잠수함을 격침/손상시키거나 해상 이동을 억제할 목적으로 수중에 부설되는 폭발물을 말한다. 기뢰는 부설 위치, 부설 목적, 부설 방식에 따라 분류가 가능하며, 이는 Table 1과 같다.

특히, 기뢰의 부설 위치에 따라 네 가지로 분류할 수 있다. 해저 닻에 연결하여 고정된 심도를 유지하며 기뢰의 이동을 제한하는 계류기뢰, 해류를 따라 이동하는 부유기뢰, 계류기뢰 등 다른 기뢰가 고정 케이블이나 고정용 쇠사슬이 끊어져 표류하게 되는 부류기뢰, 그리고 심도가 낮은 해역에서 이동하지 않도록 고정된 해저기뢰가 있다.

Table 1. Mine table

Type	Group
Location	Moored, drifting, floating, bottom
Explosion	Contact, influence, controlled, combination
Purpose	Offensive mine, defensive mine, protective mine
Method	Warship, submarine, aircraft

이 자산들을 이용하는 해군의 주요 성분 작전은 ‘기뢰전’이다. 기뢰전은 기뢰를 부설하는 기뢰부설작전과 부설된 기뢰를 소해 및 탐색 처리하는 기뢰대항

작전으로 크게 구분된다.

기뢰대항작전(mine counter measures operations, MCM Ops)은 기뢰 부설 시도를 막고 기뢰 위협을 감소시키는 효과가 있으며 크게 2가지로 구분된다. 항공 자산, 미사일 등 군사적 자산으로 적의 기뢰 저장고 및 기뢰생산시설을 선제 공격하여 적 기뢰 부설 위협을 사전 차단하는 ‘공세적 기뢰 대항 작전’과 적 기뢰 부설 후 소해함(surface mine countermeasures, SMCM), 소해헬기(air mine counter measure, AMCM)들을 통해서 적의 기뢰 부설이 가정되는 혹은 확인된 지역에 완전히 소해가 된 항로를 목적으로 하는 ‘방어적 기뢰대항작전’이 있다.

2.1.2 방어적 기뢰 대항 작전

‘방어적 기뢰 대항 작전’은 선체고정형소나(hull mount sonar, HMS), 가변심도소나(variable depth sonar, VDS), 측면주사음탐기(side scan sonar, SSS) 등 다양한 장비를 활용해 수행한다. 그 형태는 다양하지만, 가장 기본적인 방법은 소해함이 직접 기뢰 원으로 들어가는 것이며, 해저기뢰를 처리하는 기뢰 탐색 처리 절차를 중심으로 작전을 진행한다.

기뢰 탐색 처리 절차는 접촉물의 탐색 및 탐지, 식별/위치 결정, 기뢰 여부 확인, 확인된 기뢰에 대한 처리 단계로 나뉘며, Fig. 1은 그 절차를 나타낸 것이다.



Fig. 1. Mine search & neutralization procedures

이 중 탐색 단계는 다음 작전의 수행에 지대한 영향을 미치므로 작전의 효율 측면에서 매우 중요하다. 해당 접촉물에 대해 HMS를 통해 1차 파악을 한 후, 이때 SSS 및 각종 장비를 이용해 2차 탐색을 실시하여 추가 정보를 획득한 후, 나머지 과정을 진행하므로 SSS의 의존도는 높다.

기뢰 탐색 처리 절차 외에도 SSS는 중요하다. 방어적 기뢰 대항 작전이 끝난 후에도 항로에 대한 사후 관리 측면에서 SSS를 이용하여 항로를 재탐색하고, 상륙 작전 전 선도항해를 실시하는 등 다양한 작전에서 그 활용도는 높다.

현재 기뢰전의 패러다임은 소해함에서 AUV를 진회수하는 식으로 인력 손실을 최소화하는 MUM-T (manned-unmanned teaming) 체계인 stand-off MCM을 향하고 있다. 그 속에서 SSS는 AUV에 탈부착하는 등 각 주요 작전에서 중요한 역할을 하기에, 자율적으로 움직이는 무인체계를 학습시킬 충분한 국방데이터 구축은 필수적이다.

2.2 측면주사음탐기 (side scan sonar, SSS)

SSS는 해저면의 영상을 실시간으로 탐색하는 장비로서, 해양탐사 및 지질조사, 해저 통신 및 어초 조사, 기뢰 및 잠수정 탐색 등 해양탐사와 관련한 대표적 장비라고 할 수 있다. 동작 주파수는 요구되는 깊이와 목표물의 크기에 의해서 결정된다.

SSS는 해군 작전 및 기뢰 소해 작전에서 탐지 및 정찰 도구로서 중요한 역할을 한다. 군은 해당 장비를 잠수함의 선저에 부착하거나 소해함의 예인을 통해 운영하며, 음파를 발산하고 해저면에서 반사되어 돌아오는 음파를 통해서 해저에 있는 목표물을 특정하고 위치 정보를 제공한다. Fig. 2는 대한민국 기업인 ‘소나테크’에서 만든 SSS이며, Fig. 3는 단일 케이블에 연결된 수중예인체(towfish) 시스템 구조이다.



Fig. 2. Multibeam side scan sonar (Seaview 490MD)[13]

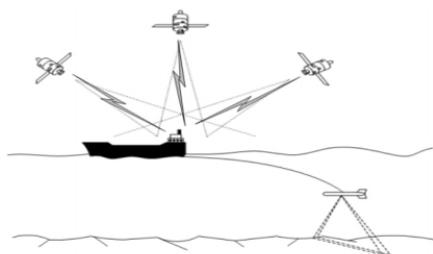


Fig. 3. The way of towing side scan sonar[2]

2.2.1 Side scan sonar dataset 소개

본 데이터셋은 Nuno Pessanha Santos 등 5명이 2024년 1월 24일에 Data in Brief 저널에 게재한 ‘Side Scan Sonar Imaging Data of Underwater Vehicles for Mine Detection’의 데이터셋을 활용했다. 이 데이터셋은 2018년부터 2021년까지 수행된 EU 국방 연구 준비 행동 계획(PADR)에 의해서 연구 자금이 마련된 OCEAN 프로젝트의 일환으로, 포르투갈 해군 공병 내 3번째 잠수부서(DMS3)에서 2015년부터 2021년까지 수집되었다.

Teledyne Marine Gavia AUV(autonomous underwater vehicle)를 수집장비로 사용했으며, 이 장비는 GPS, 관성항법장치, 고해상도의 카메라를 탑재하고 있다. Fig. 4는 해당 장비를 나타낸 것이다.



Fig. 4. Teledyne Marine Gavia AUV[25]

본 데이터셋은 총 1,170개의 이미지를 사용했으며, 2개의 클래스, 즉 기뢰 추정물(mine-like contact, MILCO)와 비기뢰해저접촉물(non-mine-like bottom object, NOMBO)로 객체를 나누었다. 해당 연도 별 이미지 개수와 그 속에 있는 MILCO의 개수와 NOMBO의 개수는 Table 2와 같다.

Table 2. Summary of the dataset

Year	Images	MILCO	NOMBO
2010	345	22	12
2015	120	238	175
2017	93	28	2
2018	564	95	46
2021	48	49	0

이 중, 데이터셋 내 해석이 요구되는 부분에 대해 연구 환경을 공유하지 않았으므로 접근이 어려운 이유로 59개 영상을 삭제했으며, 이에 대해 모델의 다양성을 일부 포기해야 했기에, 이를 한계점으로 제시했다.

### 3. 데이터 증강(Mix-up) 및 YOLOvN 소개

#### 3.1 데이터 증강 일반

데이터 학습에서 많은 양의 데이터는 매우 중요하다. 이는 과적합을 방지하고, 다양성을 증가시켜 결론적으로 가장 효율적으로 모델의 성능을 향상시킬 수 있다. 따라서, 학계에서는 다양한 방법으로 부족한 데이터 환경을 보완할 수 있는 데이터 증강(data augmentation) 기법에 대한 연구가 활발히 진행 중이며, 현재는 AI를 이용하여 데이터를 합성하는 ‘합성데이터’ 연구가 주목받고 있다.

데이터 증강은 기존의 데이터셋을 인위적으로 확장하여 데이터의 양과 다양성을 늘리는 기법이다. 이 과정에서 원본 데이터에 다양한 변형을 적용하여 새로운 데이터를 생성한다. 특히, 데이터 증강은 기존의 데이터를 쉽게 구할 수 없는 분야에서 주목을 받고 있으며, 수집의 난도와 보안을 고려해야 하는 의료 데이터, 국방 데이터가 그 대표적인 예이다.

데이터 증강의 기법은 매우 다양하다. 이미지를 일정 각도만큼 회전시키는 ‘회전’, 이미지를 x축과 y축으로 대칭시키는 반전, 밝기 조절, 잡음 추가 등이 기본적인 방법이다. Fig. 5는 데이터 증강의 기본적인 예시이다.

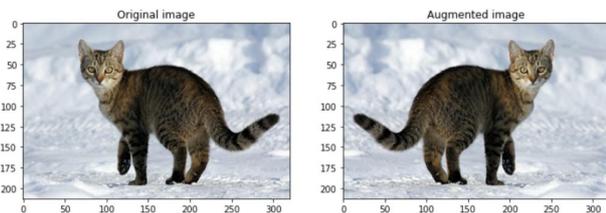


Fig. 5. Original image(left) and augmented image(right) [21]

그리고 현재는 한 가지 데이터 증강 효과를 단일하게 적용하지 않고 여러 효과를 조합하는 방법을 많이 사용하며, 데이터 증강 라이브러리를 통해서 데이터

를 증강하거나 모델 내 이미 포함되어 있는 증강 함수를 통해 데이터의 크기를 증폭시킨다.

#### 3.1.1 데이터 증강 기법

데이터 증강 기법 중 mix-up 기법은 더 많은 다양성을 확보하기 위해 사용되는 방법이다. 이 기법은 두 개의 학습 이미지와 라벨들을 간단하게 선형적으로 결합하여 새로운 샘플을 생성하는 방식이며, 사용자의 의중에 따라 두 학습 이미지의 결합하는 정도를 결정할 수 있다. 관련 공식은 식 (1)과 같으며,  $\lambda$ 를 통해서 mix-up의 정도를 결정한다. 혼합된 데이터를 학습함으로써, 다양한 데이터 분포를 경험하게 되어 과적합과 노이즈에 더 잘 대응할 수 있는 모델의 유연도 향상 및 소규모 데이터의 효과적인 데이터셋 구축이 가능하다. Fig. 6은 mix-up을 활용하여 새로운 이미지를 생성한 사례이다.

$$\begin{aligned} \hat{x} &= \lambda x_i + (1 + \lambda)x_j \\ \hat{y} &= \lambda y_i + (1 + \lambda)y_j \end{aligned} \tag{1}$$



Fig. 6. Example of image mix-up[21]

#### 3.2 객체 식별 모델과 YOLOvN 모델

##### 3.2.1 YOLOvN 모델

객체 식별은 이미지 사진이나 동영상에서 특정 물건, 사람 등 사용자가 지정한 객체를 식별하고, 해당 객체의 위치(bounding box)를 정확하게 찾기 위한 컴퓨터 시각 기술이다.

객체 식별 모델은 크게 두 가지로 구분한다. 대표적인 two-stage 모델인 R-CNN의 경우, 이미지 속 bounding box를 생성한 후, 그리고 생성된 사각형에서 분류기를 작동하는 RPN(region proposal algorithm)을 사용한다. 분류 이후, 후처리에서는 주로 bounding box를 다듬고, 중복된 식별을 제거하

며, 이미지 내 다른 객체들을 바탕으로 bounding box를 최종 선택한다. 하지만 이런 복잡한 파이프라인들은 각각 독립된 부분들이 나뉘어서 학습이 이뤄져야 하기에 느리고 최적화하기 어렵다. 그리고 이러한 과정이 순차적으로 이뤄지는 모델들을 two-stage model이라 칭한다. 해당 모델들은 독립적으로 region proposal과 분류를 시행해야 하기에 속도가 느리며, 최적화하기 어렵다. 따라서 이 두 개를 동시에 수행할 수 있는 one-stage model이 주목을 받고 있다.

대표적인 one-stage 모델은 YOLO(You Only Look Once)이다. 해당 모델은 대표적으로 두 가지의 장점이 있다. 첫 번째 특징은 매우 빠르다는 것이다. 복잡한 파이프라인이 필요 없으며, 새로운 이미지에 대해 네트워크를 작동한 후, 식별하기만 하면 된다. 이런 장점으로 인해서 실시간 방송에 대해서도 해당 모델이 적용될 수 있다는 시사점이 있다.

두 번째 특징은, 이미지 전체를 보면서 식별과정을 진행한다는 것이다. 이미지를 전체적으로 보지 못하는 기존의 모델과 달리 이 모델은 테스트 시간과 학습 시간 중에도 전체적인 모습까지 학습한다. 이러한 특징으로 인해서 새로운 모습이나 인풋 데이터에 대해 오류를 범할 확률이 낮기에 빠른 속도와 더불어 높은 정확성을 가진다. Fig. 7은 YOLO 모델의 간단한 도식도이다.

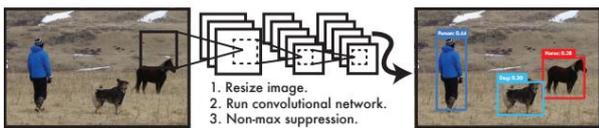


Fig. 7. YOLO detection system[23]

### 3.2.2 YOLOvN 모델 원리

YOLO 모델은 단일 신경망으로 통합된 모델인 동시에 객체를 둘러싸고 있는 bounding box를 예측하기 위하여 이미지 전체의 특징을 활용하며, end-to-end 학습을 거쳐 빠른 실시간 객체 검출이 가능하다.

단일 신경망인 초기의 YOLO 모델은 CNN 구조로 되어있으며, 입력 이미지로부터 특징을 추출하는 24개의 컨볼루션 계층과 bounding box, confidence score를 예측하는 두 개의 전결합 계층으로 구성되어 있다. 이 구조는 Fig. 8에 자세히 나타냈다.

YOLO는 입력 이미지를  $S \times S$ 로 격자를 나누는 다음, 각각의 격자는  $B$ 개의 bounding box와 그에 대한 confidence score를 예측한다. 여기서 confidence score는 bounding box가 객체를 포함한다는 것을 얼마나 신뢰할 만하고 정확한지를 보여준다.

입력이미지 속 물체에 대한 bounding box는 4개의 좌표( $x, y, w, h$ )로 구성되어 있다. ( $x, y$ ) 좌표 쌍은 bounding box 중심의 0~1 사이의 상대적인 값을 갖는 격자 내 상대 위치를 말한다. ( $w, h$ )는 역시 0~1 사이의 값을 가지며, 이미지 전체의 너비와 높이를 1이라고 했을 때 bounding box의 상대적인 값을 나타낸다.

각 격자는 또한 예측된 물체가 어떤 종류인지 나타내는 confidence score를 예측하고, 각 격자의 예측을 결합하여 최종적으로 물체의 위치와 종류를 결정한다.

현재 YOLO 모델은 one-stage 신경망의 대표적인 모델로서 간단한 처리과정으로 속도와 객체에 대한 식별도가 꾸준히 갱신되었다. 공식적인 논문은 v3

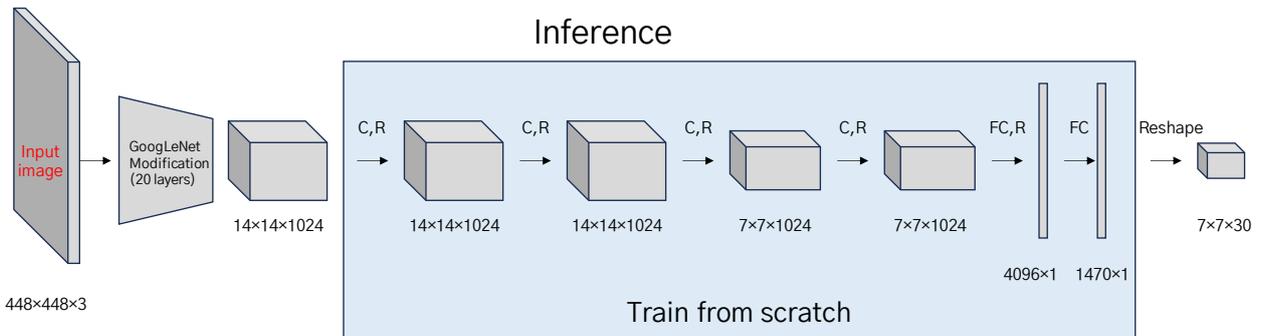
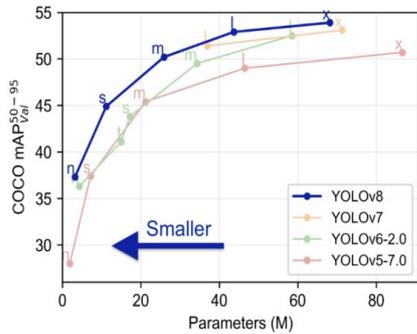
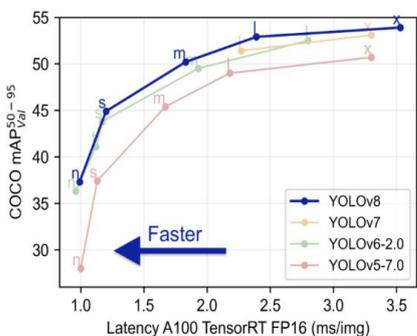


Fig. 8. YOLO architecture[23]

버전에서 종료되었지만, 사용자들의 참여에 힘입어 YOLOv9까지 연구되어 있다. Fig. 9은 모델 버전에 따른 정확도 및 속도의 증가 추이 그래프이다.



(a) Parameters and accuracy ( $mAP_{50:95}$ )



(b) Speed and accuracy ( $mAP_{50:95}$ )

Fig. 9. Comparisons between YOLOv8 and other models [26]

## 4. 데이터 구성, 실험과 결과

### 4.1. 데이터 구성

#### 4.1.1. 실험 목적 및 구성

본 연구의 실험은 부족한 기뢰 식별 국방데이터 중 합성데이터의 효과, 특히 image mix-up 기법이 side scan sonar 이미지 데이터에 대해 기존 모델보다 객체탐지 모델 성능향상에 얼마나 효과적인지 확인하기 위해 진행했다.

Image mix-up 합성에 이용되는 이미지들은 서해 연안 환경을 선정하였다. 서해의 경우, 동해보다 심도가 낮으면서 어망, 어초, 사구 등 다양한 연안 해저 접촉물들이 존재하며, 이에 따라 해저기뢰를 부설하기 쉽기 때문이다.

### 4.1.2 실험 데이터셋 소개

실험에 사용할 장비는 기뢰전에서 중요한 장비이지만 데이터 수집 난이도가 높아 별로 연구되지 않은 ‘측면주사음탐기 (side scan sonar, SSS)로 선정했으며, 3장에서 언급한 데이터셋을 활용했다. 그리고 이를 구성하는 사진들 중 해석이 필요한 사진과 더불어 학습 시 장애를 일으키는 영상 41장을 제거해 실험을 진행했고, 최종적으로 이용한 데이터는 1,129 장이다. Fig. 10은 기뢰추정물(MILCO)을 포함한 이미지이며, 흰색 원은 MILCO이다.

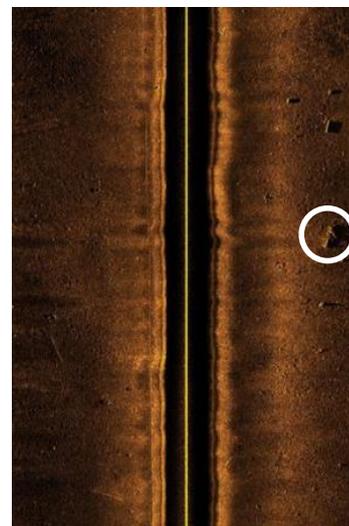


Fig. 10. Side scan sonar image (2015) and 1 MILCO[25]

### 4.1.3 실험 데이터셋 증강

실험에 사용한 데이터 증강 기법은 image mix-up이며, 해당되는 참조 이미지를 선택하기 위해 다양한 논문들과 소해함 작전관 경험을 고려했다. 국토해양부 해양환경정책관에 의하면, 서해는 한반도와 중국 대륙으로 둘러싸인 얇은 수심의(평균 44 m) 반(半)폐쇄성 대륙붕 바다로, 해저에는 한반도와 중국 대륙의 크고 작은 강들을 통해 흘러들어온 많은 양의 퇴적물이 쌓여있다. 또한, 서해 연안으로부터 다소 떨어진 해저에는 독특한 모래 구조의 사퇴들이 광범위하게 북동-남서 방향으로 광범위하게 발달하고 있으며, 평택 연안 쪽에는 해저 모래언덕이 있는 것이 특이점이다. Fig. 11은 서해 해저의 저질과 해저에 발달한 모래언덕(사구, sandwave)을 보여준다.

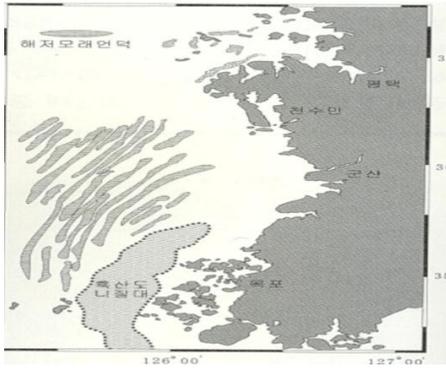


Fig. 11. Sedimentary environment of the West Sea coast [27]

이 특징들을 고려하여, 낮은 수심과 세계적으로 높은 조수간만의 차로 인해 서해에서는 계류기뢰 설치가 제한되나, 수심과 조수간만의 차에 영향을 비교적 덜 받고, 모래나 진흙으로 인해서 식별이 어려운 해저 기뢰 부설은 용이할 것으로 판단했다.

특히, 2019년 3월 18일부터 11월 20일까지 수로측량과에서 진행한 연안해역 조사에 의하면, 적(敵)과 상대적으로 거리가 가까운 인천 부근에서는 사주가 발달하고 어망이 산재해 있다는 특징이 확인되었다. 더불어 덕적도 부근의 굴업도 권역에서는 전반적으로 완만한 경사의 사질, 자월도 남쪽 구역과 대이작도 북서쪽에서는 인공어초가 확인되었다.

이 특징들을 종합하여 image mix-up을 진행하였다. 서해 해역의 많은 모래 퇴적물이 많은 특징을 반영하기 위하여 side scan sonar로 찍은 sandwave 사진과 어초와 같은 소규모 접촉물들이 많다는 특징 및 저자의 경험을 고려해, 어초, 잔해, 굴 양식장 사진을 이용하여 mix-up을 진행했다. Figs. 12-15은 그에 대한 mix-up의 예시이다.



Fig. 12. Image mix-up with sandwave

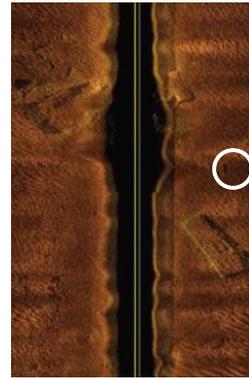


Fig. 13. Image mix-up with debris

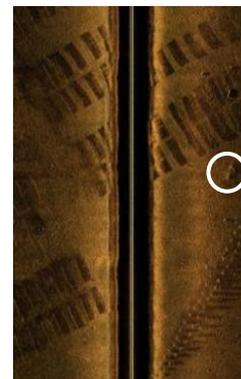


Fig. 14. Image mix-up with oyster bed



Fig. 15. Image mix-up with fish habitat

## 4.2 실험 및 결과

### 4.2.1 실험 환경과 평가지표

실험은 Google Colaboratory Pro를 활용했고, 세부적인 실험 환경은 Table 3와 같다.

평가지표는 모델이 이미지 내에서 객체를 탐지한 정도를 평가하기 위해 사용되는 일반적인 지표를 사

용했다. 평가지표는  $P$ (precision, 정확도),  $R$ (recall, 재현율),  $mAP_{50}$ ,  $mAP_{50:95}$ 이다.

**Table 3.** Google Colaboratory Pro environment

Parts	Name and specs.
GPU	Tesla T4
CPU	12th Intel Core i5-12500H
RAM	32 GB
CUDA	11.8
Python	3.10.12
Framework	Colab

#### 4.2.2 객체탐지 모델 학습

객체탐지 모델은 YOLOv8m을 사용했으며, 비교군 역시 동일한 실험 환경에서 학습을 진행했다. 실험에서는 3장에서 언급한 mix-up과 참조이미지 4개를 가지고 원본데이터 903개, 1번 mix-up 이미지 903개, 2번 이미지 903개, 3번 이미지 903개, 4번 이미지 903개 총 4,515개를 학습데이터로 구성했다. Validation set과 test set은 각각 113개씩 원본으로 구성했다.

따라서 mix-up으로 이루어진 합성데이터의 효과를 확인하기 위하여 Case #1은 원본이미지 903개, Case #2는 합성이미지 3,612개, Case #3는 무작위로 뽑은 원본이미지 451개와 합성이미지 451개, Case #4는 원본이미지 903개와 합성이미지 3,612개를 학습데이터로 만들어 비교군을 형성했다. Table 4는 이를 정리한 것이다.

**Table 4.** Composition of experiment dataset

Experiment dataset	Case #1	Case #2	Case #3	Case #4	
Train	Basic	903	-	451	903
	mix-up	-	3,612	451	3,612
Validation set	113	113	113	113	
Test set	113	113	113	113	
Total set	1,129	3,838	1,128	4,741	

학습 간 hyper-parameter는 사전학습된 YOLOv8

모델의 기본값을 사용했다. Image size는 416\*416, batch size는 16으로 설정하였으며, optimizer는 auto를 사용해서 객관적인 성능을 확인하고자 하였다. 원본 이미지만을 학습시키는 경우, optimizer는 AdamW, learning rate initial은 0.01, momentum은 0.937, weight decay는 0.0005로 설정하였으며, 그 외 경우 optimizer는 SGD 및 이하 hyper-parameter들은 동일하게 진행했다. 모든 실험에서 epoch는 동일하게 100으로 실시했다.

#### 4.2.3 실험 결과

Table 4의 비교군을 가지고 실험을 실시한 결과는 Table 5와 같다.

**Table 5.** Experiment result

Parts	Precision	Recall	$mAP_{50}$	$mAP_{50:95}$
Case #1	0.57	0.417	0.455	0.261
Case #2	<b>0.83</b>	0.501	0.593	0.354
Case #3	0.517	0.405	0.393	0.204
Case #4	0.812	<b>0.749</b>	<b>0.746</b>	<b>0.43</b>

먼저, 원본 데이터셋과 증강된 데이터셋에 대해 각각 성능을 비교했다. Case #1의 경우, precision 0.57, recall 0.417,  $mAP_{50}$  0.455,  $mAP_{50:95}$  0.261이 나왔으며, 이와 비해 Case #2 학습을 진행한 경우, precision 0.83, recall 0.501,  $mAP_{50}$  0.593,  $mAP_{50:95}$  0.354가 나와 모든 지표에서 성능이 향상된 것으로 나타났다. 증강에 의해 데이터의 양과 다양성이 증가한 것이 이러한 결과에 가장 큰 역할을 한 것으로 추측된다.

또한 Case #3에서는 precision 0.517, recall 0.405,  $mAP_{50}$  0.393,  $mAP_{50:95}$ 는 0.204의 성능을 보여줬으며, Case #1과 비교했을 때 mix-up임에도 불구하고 모든 지표가 하향하는 결과가 도출되었다. 원본 이미지가 데이터에 포함되면서 오히려 노이즈가 추가되어 이러한 결과가 나타났다.

Case #4 연구 결과, precision 0.812, recall 0.749,  $mAP_{50}$  0.746,  $mAP_{50:95}$  0.43으로 다른 #1, #3의 연구들보다 모든 지표에서 유의미한 향상을 확인할 수 있었다. 특히 precision 지표의 경우 #2보다는 낮으

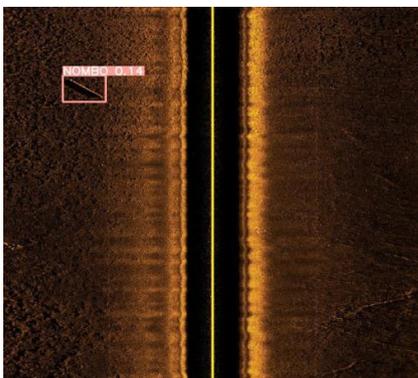
나 recall 값은 월등히 높다. 이는 실제 data 내 정답 값 중에서 정답으로 예측한 정도를 나타내는 지표가 recall이기에, 예측 실패가 큰 영향을 끼치는 기뢰 식별 분야에서는 recall 값이 높은 Case #4의 값이 더 높다고 볼 수 있다. 위와 같은 실험을 통해 합성 데이터를 통한 데이터 증강은 데이터의 양과 다양성을 향상시키고 노이즈에 대응할 수 있는 모델의 유연성을 증대시켜 식별 모델 성능의 유의미한 향상이 가능하다는 결론을 도출했다.

또한, 성능이 우수한 #4번 case에 대해 epoch를 300과 500으로 더 추가실험을 진행하였다. Epoch 500에서 precision 0.944, recall 0.842,  $mAP_{50}$  0.905,  $mAP_{50:95}$  0.684로 매우 준수한 성능을 나타냈으며, 실험 결과는 Table 6와 같다.

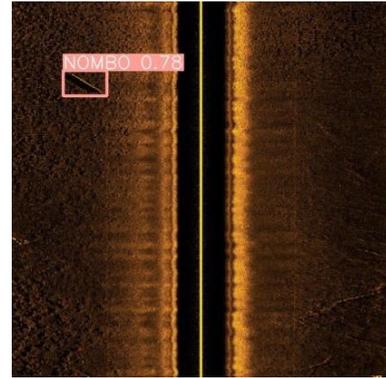
**Table 6.** Additional experiment result of Case #4

	Epoch	Precision	Recall	$mAP_{50}$	$mAP_{50:95}$
300	All	0.876	0.792	0.876	0.623
	MILCO	0.843	0.818	0.86	0.599
	NOMBO	0.909	0.767	0.892	0.647
500	All	<b>0.944</b>	<b>0.842</b>	<b>0.905</b>	<b>0.684</b>
	MILCO	0.933	0.838	0.9	0.651
	NOMBO	0.955	0.846	0.91	0.717

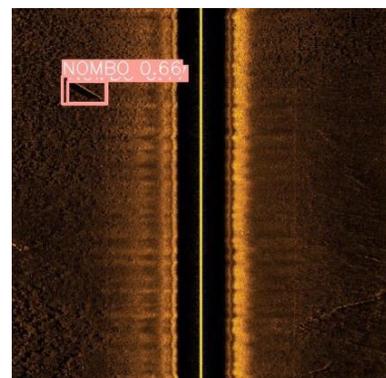
Figs. 16-19은 Table 4의 case별 비기뢰추정물(NOMBO) 예측 결과를 사진으로 나타낸 것이다. 똑같은 객체에 대해서 Case #4의 모델의 객체에 대한 신뢰도(0.83)가 다른 case들을 이용한 모델들보다 높은 것을 확인할 수 있다.



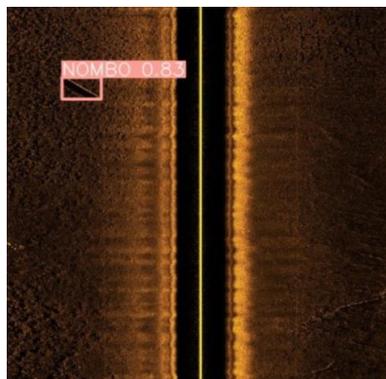
**Fig. 16.** Detecting NOMBO with Case #1 model



**Fig. 17.** Detecting NOMBO with Case #2 model



**Fig. 18.** Detecting NOMBO with Case #3 model



**Fig. 19.** Detecting NOMBO with Case #4 model

## 5. 결론

### 5.1 실험결과의 요약

본 연구는 방어적 기뢰 대항 작전에서 중요한 역할을 하는 측면주사음탐기(side scan sonar, SSS)에 대한 실시간 객체탐지 모델의 성능을 향상하기 위한 연구이다. 기뢰부설 가능성이 있는 서해의 연안 접촉물

을 참고해 원본 데이터에 대해 mix-up 방법을 이용, 데이터의 다양성과 양을 효율적으로 증강했다. 이후 데이터셋을 네 가지의 case로 나눠서 실험을 진행했고, YOLOv8 모델을 활용해 실시간 객체 탐지 모델에서 나온 성능 지표를 비교한 후 결과를 확인했다.

실험 결과, 기존 실험 가설과는 다르게 원본 이미지와 증강 이미지를 1:1 비율로 합친 데이터셋의 성능이 가장 낮게 나타났다. 이는 원본 이미지만으로 이뤄진 데이터셋보다도 낮은 성능으로, 원본 이미지가 오히려 노이즈 역할을 했을 것이라 추측한다. 가장 성능이 높게 나온 것은 Case #4 데이터셋이었다. 실험 결과,  $mAP_{50}$ 은 0.746,  $mAP_{50:95}$ 는 0.43이며, 이를 통해 합성데이터를 통한 데이터 증강이 데이터의 숫자와 다양성을 증가시켜 모델의 유연성에 기여했고, 이에 mix-up 방식이 모델의 성능을 효과적으로 늘린 것을 확인했다.

## 5.2 연구의 의의

본 연구가 주는 의의는 총 3가지이다. 첫 번째로 군 특성상 보안으로 인해 접근이 어려운 국방 데이터를 다뤘다는 점이다. 기뢰 식별 과정에서 주요 장비인 side scan sonar의 경우 해당 장비를 운용하는 데 난도가 있으며, 또한 관련 논문들을 위해 진행할 경우 많은 예산과 어려움이 따르는 것이 현실이다. 그리고 해당 장비의 image는 인터넷에서 구하기 어렵다는 점, 더불어 기뢰추정물을 촬영한 사진은 더욱 구하기 어렵다는 점을 감안할 때 타 논문과 달리 데이터셋을 입수해 실험을 수행했다는 점에 본 연구가 주는 의미가 있다.

두 번째로는 해군 기뢰전 내용에 대한 접근이다. 많은 선행 연구에서 side scan sonar(SSS) 이미지와 실시간 객체 인식 모델을 결합하고 성능을 높이고자 시도하였다. 하지만 기뢰가 아닌 소형 접촉물을 인식하는 시도가 대부분이었으며, 기뢰 식별 모델에 대한 구상은 많았지만, 데이터셋 수집의 어려움으로 인해 실질적인 모델은 부재한 상태였다. 따라서, 본 연구는 이러한 한계를 극복하고자 기존 논문들이 다루지 않았던 기뢰전 내용에 대한 논문을 서술했으며, 실질적인 실시간 객체 탐지 모델을 제시하여 한계점을 극복했다.

세 번째로는 효율적인 데이터 증강으로 모델 성능

을 유의미하게 향상했다는 점이다. 생성형 AI를 활용한 데이터 증강의 경우, 모델을 학습시킬 데이터를 온라인에서 구할 수 없는 등 수집 난이도가 매우 높기에 기본적인 데이터 증강 기법에 초점을 맞추었다. 또한 데이터 증강 기법 중 mix-up을 적용하면서 해저기뢰가 주로 부설될 가능성이 높은 서해의 특징인 모래 저질, 어망, 어초, 굴 양식장 등을 참고해 다양한 합성데이터를 증강했다. 따라서, CycleGan과 같은 다수의 학습데이터가 필요한 생성형 AI의 대안으로 mix-up 방식을 사용해 효율적으로 데이터의 다양성과 양을 늘렸고, 모델의 유연성을 증가시켰다.

## 5.3 연구의 한계 및 향후 연구 방향

상술한 연구의 차별성과 의의에도 불구하고 본 연구가 갖는 한계점은 다음과 같다.

첫째, 본 연구에서 활용한 데이터셋 수집 환경 및 배경에 대한 공유가 부재했다. 연구자가 직접 데이터 수집에 참여하지 않았기에 데이터셋 내 해석이 요구되는 부분에 대해서 접근하기 어려웠으며 결국에는 해당 이미지들을 삭제하여 모델의 다양성을 일부 포기해야만 했다. 따라서, 향후 연구에서는 데이터셋 수집 환경에 같이 참여하여 이미지 데이터에 대한 정보를 공유해야 한다.

둘째, 사용되었던 장비에 대한 한계점을 들 수 있다. 포르투갈 해군과 대한민국 해군의 SSS 장비간에 차이점이 존재한다. SSS의 경우 얻고자 하는 접촉물의 거리와 해상도에 따라 사용하는 주파수 대역폭이 다르다. 해당 데이터셋을 얻기 위해 사용한 포르투갈 공병 잠수부의 AUV 대역폭은 900 khz - 1,800 khz이며, 이는 대한민국에서 사용하는 해군의 장비와 다를 것으로 추측한다.

셋째, 자료를 수집한 포르투갈의 해역과 대한민국 서해 간에 다양한 차이점이 존재한다. 수심이 낮은 서해에는 어망, 침선 등 다양한 접촉물이 다수 산재한다. 이런 이유로 접촉물이 별로 없었던 원본 데이터 내에 mix-up을 통해 접촉물들을 추가했고, 모델의 다양성이 확보되어 성능 지표를 향상시켰다. 또한, 모래와 갯벌로 이뤄진 저질 특성으로 인해 매물될 확률 또한 높다고 생각해, 모래 지형을 합성했다. 하지만 결국에는 인공적으로 만든 환경이 아닌 자연적으로 생성된 환경에서 수집한 데이터가 테스트 환경에

서도 가장 효과가 좋다는 점을 감안할 때, 해당 해역에서 직접 데이터를 수집해 연구를 진행한다면 연구 결과의 신뢰성을 제고할 수 있을 것이다.

본 연구에서 수행한 연구가 많은 제한점을 가지고 있기는 하나, 국방개혁 4.0의 일환으로 시행되는 해군 유·무인 복합체계 내에서 기뢰 관련 데이터 부족 문제에 도움을 줄 것이라 생각하며, 향후 국방 데이터의 개방 등의 장애물들이 해결된다면, 더 나은 발전적인 연구가 가능할 것이라 판단한다.

## 참고문헌

- [1] 강지영, 김우주. “딥러닝을 적용한 영상기반 군함 식별정보 획득에 관한 연구.” 『한국군사과학기술학회지』, 제25권 제1호, pp. 55-64, 2020
- [2] 계중음, 조재일, 유원필, 최성록, 박재현, “측면주사음탐기 센서 기술 동향 및 응용.” 한국전자통신연구원, 2023
- [3] 김다빈, 김영도. “국방 AI 학습데이터 부족 극복 방안: 합성데이터의 활용.” 『국방논단』, 제1937호(23-12), pp. 1-12, 2023
- [4] 김선준, 노상현, 김중현. “인공지능(머신러닝)을 활용한 대함 무기효과 추정방안 연구.” 『국방정책연구』, 제142호, pp. 193-222, 2023
- [5] 김준영, 신창홍, 김경희. “소나와 무인기뢰처리기 정보를 활용한 기뢰전 체계 설계 방안.” 한국정보통신학회, 2014
- [6] 김선호. “해양교통로(SLOC)의 위협과 안전확보 방안.” 『대한정치학회보』, 제23집 제3호, pp. 239-257, 2015
- [7] 김수환, 채한결. “Mask R-CNN을 이용한 이미지 합성 기반 데이터 증강의 자주포 객체탐지 모델 성능향상 연구.” 한국산학기술학회, 2023
- [8] 임광혁. “주요 국가들의 기뢰대항작전용 무인수상정 운용 발전 추이와 시사점.” 『주간국방논단』, 제1705호, pp. 1-7, 2018
- [9] 임승균, 강동수. “YOLO 알고리즘을 이용한 전차 국적 식별 및 평가.” 정보과학회. 2021
- [10] 장선호. “해양교통로(SLOC)의 위협과 안전확보 방안.” 『대한정치학회보』, 제23집 제3호, pp. 239-257, 2020
- [11] 조윤철. “특집: 해군 빅데이터 분석체계 발전방향.” 『대한조선학회지』, 제57권 제1호, pp. 21-26. 2020
- [12] 홍성준, 정인식, 박승수. “4차 산업혁명 신기술로 무장한 기뢰위협과 우리의 대응방안.” 한국해양과학기술학회. 2020
- [13] 소나테크. “Multibeam Side Scan Sonar (Seaview 400 Series).” 2019
- [14] 고용노동부. “고령화로 2030년까지 15~64세 생산가능인구 320만명 감소.” 『정책브리핑』. 2022. 2. 3.
- [15] 김예원. “10년 후 나라 지킬 군인 없어.. 또 나온 여성징병제 가능할까.” 『뉴스1』, 2023. 12. 13, <https://www.news1.kr/society/incident-accident/5259451> (검색일: 2024. 5. 11.).
- [16] 저출산고령사회위원회. “저출산 5대 핵심과제에 대한 ‘2024년 예산안’ 톨아보기.” 정책참고자료, <https://www.betterfuture.go.kr/front/policySpace/policyReferenceDetail.do?articleId=22&listLen=10&searchKeyword=&position=S> (검색일: 2024. 3. 26.).
- [17] 박태유. “해상무기이야기: 기뢰전함.” Bemil 군사세계, [https://bemil.chosun.com/nbrd/bbs/view.html?b\\_bbs\\_id=10002&pn=5&num=950](https://bemil.chosun.com/nbrd/bbs/view.html?b_bbs_id=10002&pn=5&num=950). (검색일: 2024. 5. 15.).
- [18] 통계청. “합계출산율.” 지표누리, [https://www.index.go.kr/unity/potal/main/EachDtlPageDetail.do?idx\\_cd=1428](https://www.index.go.kr/unity/potal/main/EachDtlPageDetail.do?idx_cd=1428), 2023. (검색일: 2024. 3. 25.).
- [19] 해군본부. “해군의 역할.” [https://www.navy.mil.kr/mbshome/mbs/navy/subview.do?id=navy\\_010400000000](https://www.navy.mil.kr/mbshome/mbs/navy/subview.do?id=navy_010400000000) (검색일: 2024. 3. 25.).
- [20] Raul (Pete) Pedrozo. “함반도 전쟁 시 해상 기뢰전.” 『한국해양전략연구소 Periscope』, 제301호, 2022
- [21] Buslaev, Alex et al. “Albumentations: Fast and Flexible Image Augmentations.” Journal of Open Source Software, Vol. 5, No. 52, p. 2501. 2020
- [22] Feihu Zhang et al. “Detection of Small Objects in Side Scan Sonar Images Using an Enhanced YOLOv7-Based Approach.” Journal of Marine Science and Engineering, Vol. 11, No. 11, 2155. 2023
- [23] Joseph Redmon et al. “You Only Look Once: Unified, Real-Time Object Detection.” 2016
- [24] Jaebeom Park et al. “Enhancing Side-Scan Sonar Imaging: A Comparative Study of Deep Learning Super-Resolution Techniques.” 2024
- [25] Nuno Pessanha Santos et al. “Side-scan Sonar Imaging Data of Underwater Vehicles for Mine Detection.” 2024
- [26] Redmon, Joseph, et al. “YOLOv8: You Only Look Once Version 8.” 2021, <https://docs.ultralytics.com/>
- [27] 국토해양부 해양환경정책관실. “서해연안해역의 지형과 퇴적환경,” 2009. 12. 22, [https://blog.naver.com/mltm\\_ocean/60097788513](https://blog.naver.com/mltm_ocean/60097788513) (검색일: 2024. 5. 12.).