

Label-Efficient Maritime Radar Target Detection for Intelligent Combat Management System via Domain Adapted Self-Supervised Learning

Ju-Mi Park*, Da-Huin Moon*, Hyeon-Mo Kim*, Woo-Hyeon Moon*,
Seo-Ho Lee*, Hyo-Jo Lee*, Won-Seok Jang*, Ji-Seok Yoon*

*Engineer, Naval SW Team 2, Hanwha Systems, Seoul & Pangyo, Korea

[Abstract]

Maritime radar provides essential wide-area surveillance for naval Combat Management System (CMS), yet 'object-like' clutter often leads to False Positives (FPs) that compromise system reliability. This research focuses on analyzing these FPs to develop strategies for enhancing the autonomy and reliability of maritime situational awareness. First, we empirically establish the operational performance ceiling for post-detection FP suppression ($AUROC \approx 0.844$), demonstrating that hand-crafted features are fundamentally insufficient to resolve the physical indistinguishability of clutter. To overcome this limitation, we propose a Radar-Aware MAE (RA-MAE), a label-efficient detection framework based on a domain-adapted self-supervised learning strategy. In particular, a Blob-Priority Masking module is introduced to encourage the encoder to extract high-dimensional structural patterns from extensive unlabeled radar data. Experimental results demonstrate that RA-MAE significantly improves detection performance in data-scarce regimes. Notably, with a 10% label ratio, the proposed framework achieved a 9.2% reduction in FPs while maintaining target recall. Furthermore, a comprehensive analysis provides practical operational guidelines to optimize the trade-off between annotation costs and computational resource investment. Consequently, this research establishes a viable technical trajectory for enhancing the operational reliability and autonomy of naval maritime situational awareness by transitioning from heuristic feature engineering to representation learning.

► **Key words:** Intelligent Combat Management System, False Positive Suppression, Self-Supervised Learning, Maritime Radar Representation Learning, Label-Efficient Learning

-
- First Author: Ju-Mi Park, Corresponding Author: Ji-Seok Yoon
 - *Ju-Mi Park (jumipark1126@hanwha.com), Naval SW Team 2, Hanwha Systems
 - *Da-Huin Moon (dahuinmoon@hanwha.com), Naval SW Team 2, Hanwha Systems
 - *Hyeon-Mo Kim (hyeonmo1227@hanwha.com), Naval SW Team 2, Hanwha Systems
 - *Woo-Hyeon Moon (moonstar@hanwha.com), Naval SW Team 2, Hanwha Systems
 - *Seo-Ho Lee (lshpilot@hanwha.com), Naval SW Team 2, Hanwha Systems
 - *Hyo-Jo Lee (hjwish.lee@hanwha.com), Naval SW Team 2, Hanwha Systems
 - *Won-Seok Jang (cws0714@hanwha.com), Naval SW Team 2, Hanwha Systems
 - *Ji-Seok Yoon (jsyoon2118@hanwha.com), Naval SW Team 2, Hanwha Systems
 - Received: 2026. 07. 23, Revised: 2026. 08. 25, Accepted: 2026. 09. 16.

[요 약]

함정 전투체계에서의 해상 레이더는 광역 감시의 핵심 역할을 수행하나, ‘객체 유사’ 클러스터로 인한 오탐은 시스템 신뢰성을 저하시키는 요인으로 작용한다. 따라서 본 연구에서는 오탐 문제를 분석하여 상황 인식의 자율성과 신뢰성을 향상시키는 방안을 모색한다. 먼저, 사후 오탐 억제 성능 상한선(AUROC ≈ 0.844)을 실증적으로 규명함으로써, 수동 설계 특징만으로는 클러스터의 물리적 구별 불가능성을 해결하는 데 제약이 존재함을 입증하였다. 이를 해결하기 위해, 본 연구에서는 도메인 적응형 자기지도 학습 전략 기반의 라벨 효율적 탐지 프레임워크인 ‘RA-MAE’를 제안한다. 특히 블롭 우선 마스킹 모듈을 도입하여, 방대한 양의 unlabeled 데이터로부터 레이더 패턴을 효과적으로 학습하도록 유도하였다. 실험 결과, RA-MAE는 데이터 희소 환경에서 탐지 성능을 유의미하게 향상시켰으며, 특히 10%의 라벨 데이터만으로도 표적 재현율을 유지하며 오탐을 9.2% 감소시키는 성과를 거두었다. 나아가 포괄적인 분석을 통해 어노테이션 비용과 컴퓨팅 자원 투자 사이의 최적 균형점에 대한 실무적인 운용 지침을 제시하였다. 결과적으로 본 연구는 수동 특징 설계에서 표현 학습으로의 전환을 통해, 해상 상황 인식의 운용 신뢰성과 자율성을 제고할 수 있는 실질적인 기술적 경로를 제시한다.

▶ **주제어:** 지능형 함정전투체계, 오탐 억제, 자기 지도 학습, 해상 레이더 표현 학습, 라벨 효율적 학습

I. Introduction

함정 전투체계는 복잡한 해상 환경에서 상황 인식 능력을 확보하고 신속한 의사결정을 내리기 위해 수많은 센서와 무기 체계를 통합하여 운용한다. 그중 레이더는 광역 환경에서 잠재적 표적을 탐지하고 추적하기 위한 핵심 역할을 담당한다. 함정 전투체계의 정확하고 즉각적인 상황 인식을 수행하는 능력은 단순한 운용상의 이점을 넘어, 생존성과 임무 성공을 결정짓는 필수적인 요구사항이다.

이러한 핵심 운용을 지원하기 위해, 레이더 시스템은 신호 처리 기법을 활용하여, 배경 노이즈와 해수면 클러스터로부터 잠재적 표적을 분리해 내는 기능을 수행한다. 이를 통해 레이더 시스템은 운용자에게 기초적인 수준의 정보를 제공하여 광범위한 해석을 효율적으로 감시할 수 있도록 지원한다[1].

그럼에도 불구하고, 실제 운용 환경에서는 “객체 유사(Object-like)” 클러스터라는 근본적인 물리적 과제가 존재한다. 해수면 파도의 주기가 레이더 파장의 약 절반에 도달하면 브래그 산란(Bragg scattering)이 발생하며, 이는 객체의 레이더 단면적(RCS, Radar Cross Section)과 통계적으로 매우 유사한 신호를 생성한다[2]. 이러한 신호들은 신호 수준에서 실제 표적과 구별하기 어렵기 때문에, 전통적인 임계값 기반 탐지기에서의 오탐(FP, False Positives) 발생은 불가피하다.

현재 운용 환경에서는, 이를 식별하기 위해 숙련된 운용

자가 경험을 바탕으로 필터링하여 시스템의 신뢰성을 보완한다. 다만, 이러한 운용자 중심의 식별 과정은 장시간 운용 시 인지적 피로도를 높이는 주요 요인이다. 따라서, 자동화된 필터링의 정밀도를 높임으로써 운용자의 피로도를 절감하고, 함정 전투체계의 운용 효율성을 극대화할 필요성이 대두되었다.

이러한 물리적 한계를 극복하고 운용자의 부담을 경감하기 위해서, 통계적 필터링에서 벗어나 고차원 공간 패턴을 인식할 수 있는 인공지능 기반의 자동화된 탐지 프레임워크로의 전환이 필요하다. 신호 강도에 의존하는 전통적인 방식과 달리, 학습 기반 접근법은 복잡한 구조적 특징을 추출함으로써 정교한 클러스터와 실제 표적을 더욱 효과적으로 구분할 수 있다. 따라서, 고도화된 표현 학습(Representation Learning)을 통해 FP 억제 과정을 자동화하는 것은 함정 전투체계에서 탐지 신뢰도를 높이고 운용 자율성을 확보하기 위해 필수적이다.

본 연구에서는, 이러한 자동화를 구현하기 위해 두 가지 핵심 목적에 집중한 프레임워크를 제안한다.

먼저, 단일 프레임에서의 수동 설계 특징 기반 FP 억제의 실증적 성능 상한선을 조사하여, 레이더 신호만을 활용한 방법론이 도달할 수 있는 성능적 임계치를 분석한다. 본 실험 조건 내 통계적 특징 분석과 5종의 머신러닝 분류기를 활용한 교차 검증 결과, 탐지 성능의 상한선(AUROC

≈ 0.844)이 신호 수준의 물리적 구별 불가능성과 밀접하게 연관되어 있음을 확인하였다. 이는 단순한 특징 설계나 분류기 최적화만으로는 극복할 수 없는 임계점이 존재함을 의미하며, 결과적으로 이를 극복하기 위해서는 수동적인 특징 설계에서 벗어나 데이터 기반의 강건한 표현 학습으로의 패러다임 전환이 필수적임을 시사한다.

이어서, 데이터 희소 환경에서 발생하는 성능 저하 문제를 해결하기 위해 라벨 효율적 탐지 프레임워크를 제안한다. 본 연구에서는 제한된 어노테이션 예산 하에서 unlabeled 레이더 데이터에 대한 자기지도 사전학습이 최종 탐지 성능에 미치는 영향을 정량적으로 분석한다. 이를 위해 고강도 영역을 우선적으로 마스킹하여 인코더가 레이더 핵심 패턴을 학습하도록 유도하는 ‘블롭 우선 마스킹(BPM, Blob-Priority Masking)’ 전략을 적용한 ‘레이더 인식 MAE(RA-MAE, Radar-Aware MAE)’를 설계하였다. 특히 라벨 비율(10%~100%)에 따른 체계적인 요인 분석을 통해 사전학습과 라벨링 데이터 사이의 상관관계를 규명함으로써, 데이터 희소 환경에서 자기지도 학습(Self-Supervised Learning)의 효용성이 극대화됨을 실증적으로 입증하고 실무적인 운용 지침을 제공하고자 한다.

본 연구의 핵심 기여 사항은 다음과 같다.

(1) FP 억제 상한선 규명: 본 실험 조건 내 통계적 분석과 머신러닝 분류기를 활용하여, FP 억제 성능의 상한선이 수동 설계 특징의 구별 불가능성에 밀접하게 연관되어 있음을 실험적으로 실증하였다.

(2) 도메인 적응형 자기지도 학습 방법 제안: 블롭 우선 마스킹 모듈을 통해 unlabeled 데이터로부터 레이더 고유 패턴을 학습함으로써, 저라벨 환경에서도 정밀 탐지가 가능한 RA-MAE 프레임워크를 제안하였다.

(3) 요인 분석을 통한 라벨 효율적 운용 지침 제공: 라벨 비율별 성능 분석을 통해 저라벨 구간에서 사전학습의 효용성을 입증하고, 실전 배치를 위한 실무적 가이드라인을 제시하였다.

II. Preliminaries

1. Related works : FP Suppression

1.1 Traditional Radar Clutter Suppression

레이더 클러터 억제는 신호 처리 분야의 핵심 과제로서 수십 년간 연구되어 왔으며, 특히 OS-CFAR[3]은 인접 셀의 정렬된 범위 내에서 클러터 통계를 추정함으로써 불균일한 클러터 환경에서의 탐지 성능을 유의미하게 개선하

였다. 이후 CA-CFAR, GO-CFAR, SO-CFAR 등 다양한 CFAR 변형 알고리즘들이 제안되었으며, 이는 각기 다른 해상 상태와 클러터 분포에 최적화된 임계값 추정 기법을 적용하는 방식으로 발전하였다. 특히 Weiss 등[4]은 중등도 해상 상태의 X-밴드 해수면 클러터에 적절한 모델인 Weibull 분포 모델을 제시하며, 통계적 기반의 CFAR 성능 분석을 위한 이론적 토대를 마련하였다.

나아가, 해수면 클러터의 비가우시안(non-Gaussian) 특성을 정밀하게 모델링하기 위한 K-분포 모델과 특정 파동 주기에서 발생하는 브래그 공진(Bragg resonance) 현상에 관한 연구들은 본 논문에서 전개하는 물리적 상한선 해석의 결정적인 근거가 된다[2]. 특히, 급경사 파면에서 발생하는 coherent 후방 산란이 소형 선박의 레이더 단면적과 통계적으로 동등한 진폭을 생성한다는 물리적인 사실은, 단순한 임계값 조정만으로는 FP를 완전히 제거할 수 없는 근본적인 제약이 존재함을 시사한다.

이러한 CFAR 계열 알고리즘의 근본적인 한계는 학습된 공간 구조를 활용하지 않고 원시 강도(Raw intensity)에 의존한다는 점이다. 즉, 표적 반사와 유사한 강도 및 공간 범위를 가진 클러터 셀은 내부 구조적 특징과 관계없이 동일한 경보를 생성하게 된다. 이는 임계값 최적화만으로는 ‘객체 유사’ 클러터를 완전히 배제할 수 없음을 의미하며, 결과적으로 탐지 후 단계에서 고차원적인 특징을 활용한 사후 필터링 연구로 확장되는 결정적인 동기가 되었다.

1.2 feature-Based FP Suppression in Radar

feature 기반의 사후 필터링을 통해 FP 억제를 개선하려는 연구들이 다각도로 수행되었다. 도플러 스펙트럼 특징과 특징 공간 결정 영역을 활용하여 해수면 클러터 내 소형 부유 표적의 탐지 성능 향상을 보인 연구와[5], 시간-도플러 스펙트럼 및 진폭 정보를 융합한 CNN을 도입해 다양한 데이터셋에서 성능을 검증한 연구가 대표적이다[6]. 또한, 시계열 데이터를 활용해 표적과 클러터의 분리를 대조 표현 학습(Contrastive Representation Learning) 문제로 정의하여 저 SCR(Signal-to-Clutter Ratio) 환경에서의 성능을 개선한 연구[7] 역시 유의미한 성과를 거두었다. 이러한 선행 연구들은 다중 채널 정보와 시간적 변화를 효과적으로 포착하여 표적 식별력을 높였다는 점에서 중요한 학술적 가치를 지닌다.

1.3 Deep Learning Approaches to Radar FP Suppression

학습된 특징을 활용한 딥러닝 기반 방법론은 기존의 수동 특징 설계(Hand-crafted feature design) 파이프라인

을 대체하는 유력한 대안으로 적용되어 왔다. 특히 해상 레이더의 표적 식별 성능을 높이기 위해 다양한 신경망 구조가 제안되었다. 우선, 본 연구와 동일한 모달리티인 Non-coherent 광역 해상 감시 레이더 데이터를 대상으로 CNN-LSTM 네트워크를 활용하여 표적 탐지 성능을 개선하는 연구가 제안되었다[8]. 해당 연구에서는 공간 특징 및 시계열 패턴을 포착하여 표적이 없는 것으로 판단되는 영역을 블랭킹 처리하여 FP를 줄였으며, 이를 통해 도플러 정보가 없는 환경에서도 학습된 공간 특징의 유용성을 입증하였다.

또한, 수신 신호의 단시간 푸리에 변환 기반 특징을 활용하여 소형 표적 탐지 성능을 높인 FP 제어 가능 CNN 구조가 제안되었으며, 특히 분류기 헤드에 FP 확률 제어 유닛을 명시적으로 포함시켜 제어 능력을 확보하였다[9]. 아울러, 전역적 맥락과 국소적 특징의 상관관계를 동시에 모델링하는 듀얼 뷰 어텐션(Dual-view Attention) CNN을 통해 CFAR 대비 낮은 FP율을 달성한 연구가 수행되었다[10]. 특히 블록 화이트닝 처리된 시공간-주파수 스펙트로그램을 사전 학습된 CNN에 입력함으로써 소형 표적 분류 성능을 유의미하게 향상시킨 연구는, 분류기의 복잡도보다 입력 표현의 풍부함이 성능 향상의 핵심 요인임을 시사하였다[11].

이러한 선행 연구 결과들은 고정된 수동 특징이나 네트워크 구조의 개선뿐만 아니라, 데이터로부터 유용한 특징을 효과적으로 추출하는 ‘표현 학습’의 관점에서 접근할 필요가 있음을 나타낸다. 특히, 함정 전투체계와 같이 전 문가의 라벨링 비용이 높은 환경에서 데이터 자체의 내재적 구조를 학습하는 자기지도 학습은 앞서 언급한 물리적 제약과 라벨 희소성 문제를 동시에 보완할 수 있는 효율적인 방안이다. 본 연구에서는 이러한 관점을 바탕으로 레이더 도메인에 특화된 자기지도 학습 프레임워크를 제안하여 탐지 성능의 향상을 도모하고자 한다.

2. Related Works: Label-Efficient Detection via Self-Supervised Pre-training

2.1 Self-supervised Learning for Visual Representation

자기지도 학습은 인간의 어노테이션 없이 pretext task를 해결함으로써 라벨 없는 데이터로부터 시각적 표현을 학습하는 방법론이다[12]. 근래의 시각적 표현 학습은 판별적 접근 방식인 대조 학습과 생성적 접근 방식인 마스크 이미지 모델링으로 구분된다. 두 방식의 핵심적인 차이는 학습 목표에 있다. 대조 학습은 서로 다른 뷰의 동일 이미

지 임베딩을 근접시킴으로써 객체의 전역적인 불변성을 학습하는 데 집중하는 반면, 마스크 이미지 모델링은 마스크된 영역을 복원함으로써 이미지의 국소적인 구조적 세부 사항과 공간적 충실도를 학습하는 데 주안점을 둔다.

먼저, 대조 학습 패러다임의 SimCLR[13]는 데이터 증강을 통해 생성된 동일 이미지의 두 가지 서로 다른 뷰를 positive pair로, 그 외의 모든 이미지를 negative pair로 정의하는 대조 학습 프레임워크를 제안하였다. 이를 통해 별도의 라벨 없이도 데이터 내의 핵심적인 특징을 효과적으로 포착하여 다운스트림 태스크에서도 높은 성능을 보였다. MoCo[14]는 모멘텀 업데이트 기반의 키 인코더와 큐(queue)를 도입하여 배치 크기에 구애받지 않고 대량의 negative 샘플을 활용함으로써 샘플 효율성을 높였다. BYOL[15]은 다른 증강을 적용한 동일 이미지에 대하여 온라인 네트워크가 타겟 네트워크의 출력을 예측하도록 설계하여 표현 붕괴를 예방하고, negative 샘플의 필요성을 제거하였다. DINO[16]는 Vision Transformer에 자기지도 지식 증류 목적 함수를 적용하여, 별도의 영역 분할 지도 학습 없이도 self-attention 맵이 객체의 경계를 명확히 구분해내는 특성을 보였다.

반면, 생성적 접근 방식인 마스크 이미지 모델링은 사전 학습을 이미지 복원 문제로 정의한다. BEiT[17]는 BERT 프레임워크[18]를 이미지 도메인에 적용하여, 랜덤하게 마스크된 패치에 대해 사전 학습된 토큰라이저로부터 얻은 이산적 시각 토큰을 예측함으로써 패치 간의 통계적 의존성을 모델링하였다. MAE[19]는 복원 목표를 원시 픽셀 값으로 단순화하고 패치의 75%를 공격적으로 마스크하며, 원본 픽셀 값을 복원하기 위해 인코더-디코더 아키텍처를 학습한다. 이 복원 목표는 인코더가 국소 질감과 전역 구조 표현 모두를 학습하도록 유도하며, 이는 downstream 탐지 태스크로 효율적으로 전이된다.

MAE는 모든 패치 위치에서 공간 정보를 보존하므로, 정확한 바운딩 박스 위치 측정에 필요한 정보를 유지한다는 점에서 탐지 사전학습에 특히 적합하다. 반면 SimCLR은 증강에 대한 전역적 불변성을 최적화하여 분류에 적합한 표현을 생성하지만, 탐지에 중요한 공간적 세부 사항을 손실할 가능성이 있다. 이러한 차이는 본 연구에서 두 방법론을 비교 대상으로 선택한 동기가 되었다.

2.2 Self-Supervised Learning for Remote Sensing and Radar

일반적인 자연 영상을 위해 개발된 자기지도 학습 방법은 물리, 신호 통계 및 객체 스케일 분포의 근본적인 도메인 차

이로 인해 레이더 영상에 직접적으로 전이하는 데 한계가 있다. 이에 따라, 원격 탐사 및 레이더 도메인에 특화된 자기지도 학습 연구들이 단계적으로 제안되어 왔으며, 본 연구는 다음과 같은 세 가지 영역의 선행 연구를 분석한다.

첫 번째로, 광학 원격 탐지 분야에서 위성 영상과 같은 원격 탐사 데이터의 특성을 반영한 자기지도 학습 연구들이 수행되었다. SeCo[20]는 동일 지형의 계절적 시계열 불변성을 자기지도 학습 신호로 활용하여 분류 및 탐지 성능을 개선하였다. RingMo[21]는 객체가 밀집된 장면에서 소형 표적 정보가 소실되는 문제를 해결하기 위해, 다중 스케일 객체를 위한 scale-aware 마스킹 전략으로 MAE를 적용시켰다. 이를 통해 도메인 적응형 생성 자기지도 학습이 일반적인 전이 학습보다 우수한 성능을 보임을 입증하였다.

두 번째로, SAR 영상은 고유한 산란 특성을 가지기에 이를 반영한 자기지도 학습 연구가 제안되었다. SAR-JEPA[22]는 원시 픽셀 진폭 대신 다중 스케일 그래디언트 특징을 예측하는 공동 임베딩 예측 구조를 제안하였다. 이는 SAR의 엣지 및 산란 중심 패턴이 스펙클 노이즈가 섞인 진폭 값보다 표적 식별 정보를 더 안정적으로 제공한다는 물리적 특성을 활용한 것으로, 다양한 표적 카테고리류의 퓨샷 탐지에서 효과적인 성능을 보였다. 또한, SARDet-MIM[23]은 그래디언트 및 SAR-Harris 특징을 복원하는 SSMAE를 제안하여, 네트워크가 노이즈 대신 구조적 맥락과 고유 산란 특징을 학습하도록 유도해 탐지 성능 향상을 보였다.

마지막으로, 단일 채널 X-band 항해 레이더는 SAR와 달리, coherent 처리, 편광 채널 및 도플러 정보가 부재하여 정보 가용성이 매우 제한적이다. Si 등[24]은 해상 레이더 객체 탐지에 자기지도 학습 사전학습을 적용한 최초의 방법론인 SSRD를 제안하였다. 이들은 대규모 unlabeled 해상 레이더 데이터셋에서 대조 학습 기반의 pretext task를 학습시킨 후, 소규모 라벨링 데이터셋으로 인코더를 미세조정함으로써 지도학습 기준선을 크게 상회하는 성능을 달성하였으며, 이를 통해 해당 모달리티에서 사전 학습 후 탐지 전략의 유효성을 입증하였다. Wang and Li [25]은 이와 다른 준지도 학습 기반의 자기 진화 방식을 제안하여, 탐지기가 생성한 고신뢰도 pseudo-label로 모델을 반복 학습하는 구조를 취하였다.

또한, 레이더 신호 인식 분야에서도 데이터 부족 문제를 해결하기 위한 연구가 진행되고 있다. Huang 등[26]은 Masked Signal Modeling 과 도메인 적응을 결합한 자기지도 학습 프레임워크를 제안하여, 레이더 신호 분류 성능을 크게 향상시킴을 입증하였다.

이러한 선행 연구들은 대규모 unlabeled 데이터를 활용한 사전학습이 레이더 영상에서의 객체 탐지 특징 표현력을 높이는 데 기여할 수 있음을 보여주었다. 다만, 대부분의 연구가 전체 데이터셋을 활용한 최종 탐지 성능 향상에 주안점을 두어 따라, 실제 운용 환경에서 직면하는 ‘라벨 데이터의 희소성’에 따른 성능 변화나 라벨 효율성에 대한 체계적인 분석은 상대적으로 부족하다. 특히, 가용한 라벨링 예산에 따른 성능 이득의 변화를 정량적으로 규명하는 것은 자원이 제한된 함정 전투체계 환경에서의 실무적인 과제이며, 본 연구의 주요 동기가 되었다.

2.3 Label-Efficient Detection Methods

소량의 라벨 데이터만으로 성능을 극대화하기 위한 라벨 효율적 탐지 연구는 크게 준지도 학습 기반 객체 탐지, 능동 학습 기반 객체 탐지, 그리고 자기지도 학습 기반 사전학습이라는 세 가지 패러다임으로 발전해 왔다.

먼저, 준지도학습 기반 객체 탐지는 Teacher 모델의 고신뢰도 예측값으로 pseudo-label을 생성하여 학습 데이터를 보강한다. STAC[27]는 고신뢰도 바운딩 박스 생성과 강한 증강 기반의 일관성 학습을 통해 데이터 효율성을 높였으며, Unbiased Teacher[28]는 mutual mean-teacher 기법을 통해 Teacher 모델의 오류가 강화되는 확인 편향 문제를 해결했다. 다만, 준지도학습 기반 객체 탐지는 초기 모델이 신뢰할 수 있는 예측을 수행하는 중등도 라벨 구간(20-50%)에서 효과적이며, 10% 이하의 저라벨 구간에서는 pseudo-label의 품질이 모델 성능에 종속되는 의존성으로 인해 유효성이 제한된다.

능동 학습 기반 객체 탐지는 가장 정보량이 많은 샘플을 선택적으로 라벨링하여 라벨링 비용을 절감한다. Kao 등[29]은 분류 불확실성과 박스 회귀 불일치를 결합한 위치 인식 능동 선택 기법을 제안하였으며, Yuan 등[30]은 개별 인스턴스 proposal 단위로 점수를 부여하여 영역 단위의 라벨링 예산 할당을 가능하게 하였다. 능동 학습은 사전학습 품질과 의존적인 관계에 있으며, 강건한 Backbone은 초기 쿼리의 정보량을 높여주지만 선택된 샘플 당 라벨링 비용을 완전히 제거하기는 어렵다. 본 연구에서 활용한 자기지도 학습 기반 사전학습은 이러한 접근법들과 상호 보완적인 특성을 가진다.

자기지도 학습은 탐지 학습 전 오프라인 상태에서 unlabeled 데이터로부터 backbone 가중치를 학습하므로, 저라벨 구간에서 준지도 학습이 겪는 pseudo-label 품질 불안정성 문제에서 자유롭다. 예를 들어, ViTDet[31]은 MAE로 사전학습된 Plain ViT Backbone이 복잡한 구

조적 수정 없이도 탐지 태스크로 효과적으로 전이됨을 보였으며, 이는 탐지 정확도의 핵심 요인이 모델의 복잡도가 아닌 사전학습된 표현의 품질에 있음을 시사한다.

이러한 발견은 본 연구의 pretext task 설계를 위한 이론적 근거를 제공한다. 복원 기반의 사전학습이 탐지 성능에 결정적인 영향을 미친다는 점에 주목하여, 레이더 도메인의 특징인 고강도 패턴에 집중하는 도메인 적응형 마스킹 전략이 더 효과적일 것이라는 가설을 수립하였다. 따라서 본 연구에서는 패치 수준의 공간 구조를 보존하는 Radar-Aware MAE를 제안함으로써, 대조 학습 기반의 전역 불변성 표현보다 탐지 태스크로 안정적으로 전이될 수 있는 특성을 구현하고자 하였다. 제안된 가설 및 설계의 유효성은 이어지는 비교 분석을 통해 검증된다.

3. Dataset and Experimental Setup

서론에서 제안한 자동화된 탐지 프레임워크를 구현하고 FP 억제 성능 한계를 실증적으로 규명하기 위해서, 먼저 실제 해상 운용 환경의 복잡성을 반영한 실험 환경을 구축하였다. 특히, 섬 해안선 등 다양한 해상 환경을 포함하는 MOANA X-band 레이더 데이터셋[32]을 활용함으로써, 분석 대상인 '객체 유사' 클러스터의 특성 분석과 이후 제안하는 표현 학습 결과가 실제 데이터의 통계적 특성을 반영하도록 설계하였다.

3.1 MOANA X-Band Radar Dataset

본 연구에서는 선박 단일 클래스로 구성된 해상 환경 시퀀스인 MOANA X-band 해상 레이더 데이터셋을 활용하였다. 원본 2048x2048 크기의 프레임은 640x640 패치로 분할하는 타일링 전처리를 적용하였다.

본 연구에 사용된 데이터는 labeled 데이터인 1개의 시퀀스(Single Island)와 unlabeled 데이터인 3개의 시퀀스(Island Expedition, Twins Island, Complex Island)로 구성된다. 이 중 단일 섬 주변의 루프 경로를 포함하는 Single Island 시퀀스를 시계열 순으로 정렬하였으며, 이를 연속된 시간 구간별로 학습(60%), 검증(20%), 테스트(20%) 데이터셋으로 분할하였다. 이때 분할 경계의 인접 프레임을 제외함으로써 데이터 간 최소한의 시간적 여백을 확보하였다.

단일 시퀀스로 학습 시 발생하는 데이터 편향 및 과적합 문제를 해결하기 위해, 구조적 복잡성과 환경적 노이즈를 포함하는 unlabeled 시퀀스를 추가로 활용하였다. Island expedition은 여러 섬 환경을 탐색하는 경로를 포함하며, 높은 공간적 변동성을 제공함으로써 일반화 성능을 높이

는 데 기여한다. Twins island는 두 섬 사이의 좁은 경로를 포함하며, 객체와 유사한 강도 특성을 가진 클러스터가 빈번히 발생한다. 마지막으로 Complex island는 비정형적이고 산발적인 환경을 제공하여, 다양한 해수면 클러스터에 대한 모델의 강건성을 확보하는 데 활용되었다.

3.2 Baseline Model

제한된 하드웨어 자원에서도 실시간 처리가 필요한 함정 전투체계의 특성을 고려하여, 경량화되고 높은 효율성을 가진 YOLOv8s[33]을 기본 아키텍처로 채택하였다.

완전 지도 학습 기준선의 성능은 Table 1과 같다. 본 모델은 앞선 II.3.1의 데이터셋을 활용하여 학습, 검증 및 평가되었으며, 100 epoch동안 AdamW[34] ($lr=1e-3$) 최적화 알고리즘을 사용하여 학습하였다. 실험 결과, 해당 모델은 mAP₅₀에서 0.7385, FP/image에서 0.2108의 성능을 보였다. 이 결과는 본 연구의 데이터셋과 아키텍처 구성 내에서 도달 가능한 성능 상한선을 의미하며, 이후 수행되는 실험의 절대적인 비교 기준점으로 활용된다.

Table 1. Fully-Supervised Baseline

Metric	Value
mAP ₅₀	0.7385
mAP ₅₀₋₉₅	0.6509
Precision	0.6529
Recall	0.7211
F1-Score	0.6853
FP/image	0.2108
True Positives	2094
False Positives	1113
False Negatives	810

III. False Positive Suppression

1. Motivation

함정 전투체계의 레이더 시스템은 최종적으로 전술 화면에 추적 정보를 제공함으로써 지휘 결심을 지원한다. 그러나 해수면 클러스터로 인한 허위 표적은 불필요한 추적 정보를 생성하여 전술 화면의 시각적 품질을 저하시키고, 운용자의 오대응을 유발하는 원인이 된다.

특히, X-band 레이더의 허위 표적은 주로 해파면의 브래그 산란으로 인해 소형 선박의 RCS와 물리적으로 매우 유사한 후방산란 피크를 생성하는 특성을 갖는다. 이러한 신호 수준의 '물리적 동등성'은 레이더 시스템의 한계가 아닌 파동 물리학의 고유한 특성에서 기인하는 것이기에, 통계적 임계값 설정 방식만으로는 한계가 있다.

YOLOv8과 같은 딥러닝 탐지기는 공간적 맥락과 학습된 feature 계층 구조를 활용함에도 불구하고, X-band 영상에서 발생하는 선박 반사와 해수면 클러스터 간의 신호 수준 구별 불가능성을 완전히 극복하는 데에 한계가 있다. 앞선 장에서 구축한 완전 지도 학습 기준선은 높은 mAP를 달성하였으나, 실제 함정 운용 시에는 잔존하는 FP가 시스템의 신뢰성을 저하시키는 주요 요인으로 작용한다.

이에 본 장에서는 단일 프레임 수동 설계 특징을 이용한 해상 레이더 내 표적 탐지의 사후 FP 억제 파이프라인을 구축하고, 운용적 제약 사항을 실증적으로 분석하고자 한다. 본 분석은 FP 억제 성능의 수치적 상한선을 확인하는 것에 그치지 않고, 신호 수준의 구별 불가능성에서 기인하는 성능 저하 요인을 고찰함으로써, 향후 이를 개선하기 위한 고도화된 탐지 프레임워크 설계의 필요성과 이론적 토대를 제공하고자 한다.

2. Overall Framework

본 장의 목적은 단일 프레임 기반의 특징 추출과 분류 알고리즘만으로 달성 가능한 FP 억제 성능 상한선을 규명하는 것이다. 이를 위해 본 연구에서는 데이터 구축부터 통계적 분석, 분류 모델별 성능 비교에 이르는 분석 프레임워크를 제안하였다(Fig. 1).

제안하는 프레임워크는 다음과 같은 과정으로 구성된다. 첫째, ‘객체 유사’ 특성을 반영한 Hard Negative Pool 구축 단계이다. 레이더 영상에서 객체와 유사한 특성을 가진 고강도 블롭 영역을 정밀 추출하여, 고품질의 Hard Negative Pool을 구성해 분석에 활용하였다.

둘째, 구축된 표적 및 Hard Negative 샘플로부터 강도 및 형태 기반의 6종 feature를 설계 및 추출하고, 이들의 통계적 특징을 계산하였다. 이를 통해 개별 feature가 갖

는 물리적 구별 가능성을 정량적으로 도출하였다.

마지막으로, 머신러닝 분류기를 활용한 구별 성능 상한선을 분석하였다. feature들이 구성하는 feature space를 입력으로, 선형 모델부터 MLP에 이르는 다양한 분류기를 적용해 성능 상한선 및 운용적 실용성을 평가하였다.

이와 같은 단계적 분석의 신뢰성은 분석 대상인 데이터셋의 품질에 의해 결정되며, 이어지는 절에서 Hard Negative Pool 구축 파이프라인에 대해 상세히 기술한다.

3. Hard Negative Construction

FP 억제 한계를 정확하게 규명하는 데에는, Hard Negative 샘플의 품질이 결정적인 역할을 한다. 단순 배경 패치로 구성된 Negative 집합은 분류 성능을 인위적으로 과장시키는 경향이 있으며, 반대로 실제 객체가 포함된 집합은 성능을 저하시켜 신뢰할 수 없는 지표를 생성한다. 따라서 본 연구에서는 이러한 편향을 방지하고, 탐지기를 혼동시킬 가능성이 높은 ‘객체 유사’ 클러스터를 정밀하게 추출하는 파이프라인을 설계하였다.

기존의 무작위 샘플링 방식과 달리, 본 연구에서는 객체와 유사한 고강도 블롭 영역을 집중적으로 추출하는 전략을 채택하였다. 이를 통해, 배경 노이즈를 제거하고 판별 난이도가 높은 Hard Negative만을 추출함으로써 단일 프레임 기반 탐지기가 도달할 수 있는 성능 상한선을 설정하였다. 구체적인 Hard Negative 추출 파이프라인은 다음과 같은 6단계로 수행된다.

- (1) Data Pre-processing: 레이더 비디오 영상을 그레이 스케일로 변환하고, 32X32 픽셀 크기로 정규화하였다.
- (2) Adaptive Thresholding: 배경 대비 고강도 영역을 이진화하기 위해, 블록 크기 32, 오프셋 -12의 적응적 임계값 처리를 적용하였다.




Fig. 1. Overall Framework for False Positive Suppression. Stage 1: Hard Negative Construction. Stage 2: Statistical and Model-based Evaluation Comprising (A) Feature Extraction, (B) Statistical Analysis, and (C) Machine Learning Classification

- (3) Morphological Noise Reduction: 3x3 타원형 커널 모폴로지 연산을 수행하여 미세한 노이즈를 제거하였다.
- (4) Connected Component Analysis: 연결 성분 분석을 통해 이진 이미지 내 모든 독립된 영역을 탐지하고, 각 성분의 위치, 면적 및 바운딩 박스를 추출하였다.
- (5) Strict Object Exclusion: 객체의 영역이 Hard Negative Pool에 포함되는 것을 방지하기 위해, Ground Truth 주변 3% 여백을 포함한 '제외 영역'을 설정하여 해당 범위 내 모든 샘플을 배제하였다.
- (6) Area-based Filtering and Sampling: 의미 있는 클러스터 패턴을 포함하되 지나치게 큰 구조물이나 노이즈를 배제하기 위해 면적이 200~800 픽셀인 영역만을 최종 후보로 선정하였다. 이후 프레임 당 최대 5개 샘플을 추출하여 데이터셋을 구성하였다.

이러한 파이프라인을 통해, Positive 52,101개, Negative 33,964개로 구성된 고품질 데이터셋을 구축하였다. 데이터셋의 유효성을 정성적으로 검증하기 위해, 리더 프레임 상에 추출한 Hard Negative 샘플과 실제 표적의 위치를 오버레이하여 시각화하였다(Fig. 2).

Fig. 2. (A)를 살펴보면, 추출된 Hard Negative 샘플들이 실제 표적과 매우 유사한 공간적 배치와 픽셀 면적을 가지고 있음을 확인할 수 있다. 이는 제안한 샘플링 파이프라인이 배경 노이즈를 배제하고, 실제 탐지기가 표적으로 오인할 가능성이 높은 '객체 유사' 특성의 고강도 블롭 영역만을 정밀하게 추출했음을 보여준다.




Fig. 2. Qualitative Evaluation of the Constructed Hard Negative Pool (A) Overlay of Targets (blue) and Hard Negative Samples (orange) on a Zoom-in Patch, (B, C) Grids of Cropped Samples of Hard Negatives and Actual Targets, respectively.

나아가, 개별 샘플들을 격자 형태로 시각화한 결과(Fig. 2. (B, C)), Hard Negative 샘플 집합과 실제 표적의 집합이 유사한 강도 중심점과 에너지 확산 패턴을 보임을 확인

하였다. 이러한 시각적 유사성은 두 클래스가 강도 분포 측면에서 상당 부분 중첩되어 있음을 시사하며, 이는 단일 프레임 기반의 표적 식별을 어렵게 만드는 요인이 된다.

이와 같이 표적과 유사한 특성을 가진 Hard Negative Pool을 구성함으로써, 배경의 샘플 포함 시 발생할 수 있는 성능 과다 추정 편향을 완화하였다. 본 데이터셋은 이어지는 4절의 통계적 분석에서 단일 프레임에서의 수동 설계 특징 기반 표적 탐지의 실질적인 판별 성능 상한선을 규명하기 위한 기준으로 활용하였다.

4. Statistical feature Analysis

앞선 3절의 정성적 분석을 통해 표적과 Hard Negative 샘플 간의 시각적 유사성을 확인하였다. 본 절에서는 이러한 유사성을 정량적으로 검증하기 위해, 두 클래스의 핵심 속성을 정의하고 이들의 분포를 분석하였다.

4.1 feature Design Rationale

각 샘플이 지닌 판별력 있는 속성을 포착하기 위해 강도 기반 feature와 형태학적 feature로 분류된 6종의 Hand-crafted feature를 설계하였으며, 상세 설계 사항은 Table 2와 같다.

먼저, 강도 기반 feature는 샘플 내부에 존재하는 신호의 크기와 분포 양상에 집중한다. Mean Intensity는 신호의 전반적인 세기를 반영하며, Max Intensity는 객체에서 발생하는 반사로 인해 높게 나타나는 peak RCS 값을 포착한다. 또한, Std Dev Intensity를 활용해 강도 분포의 분산 정도를 측정함으로써 신호의 안정성과 대비를 정량화하였다.

이어서, 형태학적 feature는 샘플의 기하학적 구조를 표현하기 위해 설계되었다. 그 중 Energy Ratio는 상위 90% 이상의 강도를 가진 픽셀의 에너지 합을 전체 에너지로 나눈 값으로, 이는 집약된 객체가 갖는 에너지 집중도를 측정한다. 또한, 객체의 형태적 비대칭성을 반영하기 위해 바운딩 박스의 Aspect Ratio를 계산하였으며, Solidity를 통해 형태의 밀집도를 평가함으로써, 단순하고 밀집된 형태와 불규칙하고 파편화된 구조를 구분하였다.

4.2 Statistical Comparison Results

Table 2는 객체와 Hard Negative 간의 6개 feature에 대한 종합적인 통계 비교를 포함한다. 각 feature의 판별력을 엄밀히 평가하기 위해, t-검정의 p-value를 통해 통계적 유의성을 확인하고, 분포 중첩도를 통해 두 클래스의 유사성을 정량화하였으며, KL Divergence (Kullback-

Table 2. Definition of Hand-crafted Features and Statistical Results between Objects and Hard Negatives

features		Definition	Objects	Hard Negatives	p-value	Overlap (%)	KL Div.
Intensity	Mean Intensity	$\mu = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W I(i, j)$	90.64	90.99	1.76e-03	80.0%	0.1520
	Max Intensity	$I_{\max} = \max_{i,j} I(i, j)$	229.47	229.59	2.80e-07	98.8%	0.0048
	Std Dev Intensity	$\sigma = \sqrt{\frac{1}{HW} \sum_{i,j} (I(i, j) - \mu)^2}$	84.28	85.76	0.00e+00	70.2%	0.3228
Morphological	Energy Ratio	$E_{ratio} = \frac{\sum_{i,j} I(i, j)^2}{I_{\max}^2 HW}$	0.2629	0.2604	0.00e+00	79.0%	0.1914
	Aspect Ratio	$AR = \frac{W}{H}$	1.5603	1.3632	0.00e+00	85.2%	0.0865
	Solidity	$S = \frac{A_{box}}{A_{hull}}$	0.9034	0.9021	3.00e-04	92.9%	0.303

Leibler Divergence)를 통해 두 확률 분포 사이의 정보 이론적 거리를 측정하였다.

분석 결과, Max Intensity의 p-value가 2.80×10^{-7} 로 매우 낮게 나타나 표면적으로는 두 집단 간에 명확한 차이가 있는 것처럼 보였으나, 98.8%에 달하는 높은 분포 중첩도를 보여 실질적인 판별 도구로서의 효용성이 낮음을 확인하였다.

이어서, Mean Intensity 역시 80.0%의 높은 중첩도와 낮은 KL Divergence 값(0.1520)을 보여, 두 클래스의 전반적인 신호 세기가 거의 동일함을 나타냈다. 이러한 결과를 통해 X-band 영상에서 가파른 파면으로부터 발생하는 coherent 후방산란은 intensity 측면에서 소형 선박의 RCS와 물리적으로 구별 불가능하다는 점을 확인하였다.

형태학적 feature 중에서는 Std Dev Intensity가 가장 높은 KL Divergence 값(0.3228)을 기록하였으나, 70.2%의 중첩이 존재하였다. 또한, Aspect Ratio와 Solidity는 각각 85.2%, 92.9%의 높은 중첩도를 보이며 명확한 분리에 실패하였다.

본 분석은 레이더 FP 억제 문제에 있어, 운용적 실용성을 판단하기에는 p-value보다 분포 중첩도와 KL

Divergence가 신뢰할 수 있는 지표임을 보여준다. 6개 feature에서 70% 이상의 중첩도가 관찰된 사실은, 단일 수동 설계 특징만으로 선박 반사와 Hard Negative 클러스터를 신뢰성 있게 분리하는 것이 어렵다는 결정적인 결론으로 이어진다.

5. Classical Machine Learning Classifiers

5.1 Classifier Selection Rationale

앞선 실험 결과에 따라, 각 feature의 독립적인 사용만으로 Hard Negative 샘플 식별이 어려움을 확인하였다. 따라서 본 장에서는 단일 프레임 feature 기반의 Hard Negative 식별 가능성을 검증하기 위해, 수동 설계 특징들이 구성하는 feature space 기반으로 Hard Negative 식별을 수행하였다.

이를 위해, 본 연구에서는 선형(Logistic Regression), 비선형 커널(SVM, Support Vector Machine), 앙상블(Random Forest, Gradient Boosting), MLP(Multi Layer Perceptron)까지 다양한 복잡도를 가진 분류기를 선정하였으며, 각 분류기의 특징과 실험에 활용한 주요 하이퍼 파라미터는 Table 3과 같다[35].

Table 3. Hyperparameter Configurations and Performance Comparison of Various Machine Learning Classifiers for Hard Negative Discrimination

Classifier	Decision Boundary	Hyper Parameters	Theoretical Basis	AUROC	Accuracy	Precision	Recall	F1-Score
Logistic Regression	Linear	C=1.0	Linear separability of features	0.6727	0.6497	0.6624	0.8686	0.7516
SVM	Non-linear	C=1.0	Kernel-induced high-dimensional mapping	0.8371	0.7623	0.8119	0.8159	0.8030
Random Forest	Piecewise	100 trees, depth=6	Ensemble of decorrelated decision trees	0.8119	0.7436	0.7840	0.8000	0.7920
Gradient Boosting	Additive	100 trees, lr = 0.1	Sequential optimization of residual errors	0.8388	0.7615	0.8052	0.8035	0.8044
MLP	Arbitrary Non-linear	64-32, max_iter=500	Universal function approximation	0.8443	0.7689	0.8253	0.7880	0.8062

5.2 Results and AUROC Analysis

모든 분류기는 Z-score 정규화된 feature 값을 입력으로, 5-fold Cross Validation을 통해 성능을 평가하였다. 성능 평가 지표로는 최적 임계값이 정해지지 않은 상황에서도 모델의 전반적인 성능을 평가할 수 있는 AUROC(Area Under the ROC Curve)를 활용하였다.

이에 따른 각 분류기 모델별 실험 결과는 Table 3 및 Fig. 3과 같다. 선형 모델인 Logistic Regression(AUROC = 0.6727)에 비해 비선형 특징을 추출하는 SVM, Random Forest 및 MLP 모델이 전반적으로 우수한 성능을 기록하였다. 특히, 범용 근사 능력을 갖춘 MLP가 0.8443으로 가장 높은 AUROC를 달성하였다.




Fig. 3. AUROC Performance Comparison by Various Machine Learning Classifiers

여기서 주목할 점은 모델의 복잡도가 증가함에 따라 성능 향상이 둔화되는 성능 포화 경향을 보인다는 것이다. Logistic Regression에서 SVM 및 Random Forest로 전환되는 단계에서는 AUROC가 급격히 상승(0.14~0.17)하며 비선형 판별의 유효성을 입증하였다. 그러나 그 이후 Gradient Boosting과 MLP로 모델의 복잡도를 더욱 높였음에도 불구하고, AUROC의 상승 폭은 약 0.01~0.03 수준에 그치며 완만해지는 양상을 보였다.

이러한 결과는 분류기의 모델 용량을 확장하는 것이 더 이상 성능 향상의 지배적인 요인이 되지 않음을 시사한다. 즉, Random Forest 나 SVM 수준의 비선형 분류기만으로도 현재 제공된 feature space 내의 판별 가능한 신호는 상당 부분 추출되었음을 의미한다. 결과적으로, MLP가 0.81~0.85의 AUROC 범위를 유의미하게 벗어나지 못하였다는 점에서, 성능의 병목 지점이 분류 알고리즘의 한계가 아니라 단일 프레임에서 추출된 feature space 자체가 가진 본질적인 분별력의 한계에 기인함을 보여준다.

5.3 feature Importance Analysis

분류기 모델이 판단 근거로 활용하는 핵심 특징을 분석하기 위해, Gradient Boosting의 Gain과 Random Forest의 Permutation 지표를 통해 feature 별 중요도를 평가하였으며, 그 결과는 Table 4와 같다.

분석 결과, 두 모델 모두에서 Mean Intensity와 Max Intensity가 높은 중요도를 기록하였다. 이는 현재의 분류 체계에서 표적과 Hard Negative 클러스터를 구분할 수 있는 가장 지배적인 단서가 '신호의 강도'임을 의미한다. 반면, Solidity나 Aspect Ratio와 같은 기하학적 형태 특징은 매우 낮은 중요도를 보였으며, 이는 X-band 레이더 영상의 낮은 해상도로 인해 외형적 형태만으로는 두 집단을 유의미하게 분리하는 것이 불가능함을 시사한다.

그러나 이러한 결과는 역설적으로 단일 프레임 수동 설계 특징의 한계를 극명하게 나타낸다. 분석 결과에서 나타난 강도 정보에 대한 높은 의존성은, 분류기가 복잡한 구조적 특징을 학습한 것이 아니라 신호의 세기라는 일차원 정보에 의존하여 판별을 수행하고 있음을 보여준다. 앞서 언급한 브래그 산란으로 인한 '물리적 동등성' 구간에서는 표적과 클러스터의 강도 값이 서로 중첩되기 때문에, 통계량만으로 FP를 억제하는 데 근본적인 한계가 존재한다는 것을 나타낸다.

Table 4. Comparison of Feature Importance based on Gain and Permutation

feature	Gain-based Importance	Permutation Importance	
		Mean	Std
Mean Intensity	0.2894	0.165	0.0017
Max Intensity	0.2390	0.0929	0.0010
Std Dev Intensity	0.2051	0.0600	0.0008
Energy Ratio	0.1618	0.0363	0.0008
Aspect Ratio	0.0995	0.0297	0.0007
Solidity	0.0049	0.0021	0.0001

5.4 Operation Analysis and Score Distribution

최고 성능 모델인 MLP의 운용 유용성을 평가하기 위해, 다양한 임계값(Threshold) 설정에 따른 TP 유지율과 FP 감소율 사이에 존재하는 트레이드 오프 관계를 분석하였다. 이에 따라 Table 5에서 확인되는 바와 같이, FP 억제 성능은 임계값 설정에 따라 명확한 상충 관계를 보였다.

구체적으로, 임계값이 0.30일 때 42.7%의 FP 감소와 92.3%의 TP 유지율을 기록하였으나, 임계값을 0.40으로 높이면 FP 감소율은 62.5%로 향상되는 반면, TP 유지율은 84.7%로 감소하여 민감도 저하가 동반됨을 확인하였다.

이러한 수치적 경향은 운용 관점에서 결정적인 제약을 시사한다. 탐지 시스템에서 일반적으로 요구되는 90% 이

상의 TP 유지율을 확보하기 위해서는 임계값을 0.30 이하로 설정해야 하는데, 이 경우 FP 감소율은 42.7%에 그쳐 잔존 오탐지 비율이 높아 시스템 효율성이 저해된다. 반면, FP의 90% 이상을 억제하기 위해서 임계값을 0.80까지 높이면, TP 유지율이 53.6%로 하락하여 표적 누락 위험이 발생한다. 이는 III.4.2절에서 확인된 바와 같이 특징 분포 중첩으로 인해 분류 점수가 명확히 분리되지 않았기 때문이며, 임계값 조정만으로는 물리적 한계를 극복할 수 없음을 보여준다.

Table 5. Trade-off Analysis between TP Retention and FP Reduction

Threshold	Precision	TP Retention	FP Reduction
0.30	0.716	92.3%	-42.7%
0.40	0.780	84.7%	-62.5%
0.50	0.825	78.8%	-73.9%
0.60	0.858	72.5%	-81.3%
0.70	0.886	65.5%	-86.8%
0.80	0.926	53.6%	-93.3%

6. Summary and Motivation for Advanced feature Learning

본 장에서는, 레이더 비디오에서 사후 FP 억제의 운용적 한계를 실증적으로 규명하였다. 통계적 feature 분석과 머신러닝 분류기를 활용한 두 가지 분석을 통해, 해당 접근 방식이 도달할 수 있는 성능의 명확한 상한선을 확인하였다.

본 연구의 주요 결과는 다음과 같이 요약된다.

첫째, 개별 수동 설계 특징에 대한 통계 분석 결과, 단일 feature를 사용한 판별력이 부족함이 드러났다. p-value는 유의미한 결과를 보였으나, 대부분의 feature에서 70% 이상의 높은 분포 중첩도와 낮은 KL Divergence 값이 관찰되었으며, 이는 단일 feature만으로는 객체와 Hard Negative 클러스터를 신뢰성 있게 구분하는 것이 어려움을 보여준다.

둘째, 다양한 분류기의 성능이 0.8119~0.8443의 좁은 AUROC 범위로 수렴하는 성능 포화 현상이 나타났다. 선형 모델부터 비선형 모델에 이르기까지 나타난 이러한 패턴은, 성능의 병목 지점이 분류기의 용량이 아닌 feature space 자체에 있음을 시사한다.

셋째, 모델의 운용 실용성이 TP와 FP 점수 분포 간의 상당한 중첩으로 인해 제한적임을 확인하였다. 이러한 중첩은 높은 TP 유지율을 보존하면서 FP를 유의미하게 억제할 수 있는 강건한 임계값 설정을 불가능하게 하며, 이는 실제 운용 배치를 위한 성능 안정성의 부족으로 이어진다.

이러한 결과는 사후 FP 억제의 한계가 feature 설계의 미흡함이나 분류기 선택의 문제가 아니라, 단일 프레임

intensity feature가 갖는 신호 수준의 구별 불가능성에 기인한다는 결론으로 이어진다. 이러한 실증적 상한선을 극복하기 위해서는 인간의 직관에 의존한 수동 feature 설계에서 벗어나, 데이터로부터 고차원적인 패턴을 추출하는 표현 학습으로의 전환이 필수적이다.

이에 따라, 이어지는 IV 장에서는 대규모 unlabeled 데이터를 활용하여 강건하고 판별력 있는 feature를 학습하는 자기지도 학습 프레임워크를 제안한다. 사후 필터링이 아닌 탐지기 자체의 내재적 표현력을 높이는 방식을 통해, 본 장에서 규명한 실증적 상한선을 넘어 효율적인 탐지를 달성하는 방안을 제시하고자 한다.

IV. Label-Efficient Detection via Self-Supervised Learning

1. Motivation

앞선 III 장의 분석 결과는 수동 설계된 특징 기반의 사후 FP 억제가 성능 상한선에 의해 제한됨을 실증하였다. 이는 탐지 신뢰도를 제고하기 위해 통계적 필터링을 넘어, 복잡한 고차원 패턴을 포착할 수 있는 표현 학습으로의 패러다임 전환이 필수적임을 시사한다.

이러한 고차원적 표현 학습을 구현하기 위해서는 대규모 데이터를 활용한 딥러닝 기반 접근법이 효과적이며, 특히 함정 전투체계는 상시 운용을 통해 방대한 양의 unlabeled 영상을 지속적으로 수집하므로 원시 데이터 확보가 용이하다. 그러나 모델 학습의 핵심인 대규모 라벨링 데이터의 확보는 다음과 같은 세 가지 제약 요인으로 인해 매우 제한적이다.

첫째, 레이더 영상 내 클러스터와 표적을 정확히 식별하기 위해서는 숙련된 운용자의 전문 지식이 필수적이며, 이러한 인력은 제한적인 운용 부대에 국한되어 있다. 둘째, 함정 전투체계의 데이터는 기밀성으로 인해 접근 및 라벨링 가능 인원이 극히 제한된다. 셋째, 작전 지역의 해상 상태에 따라 특성이 상이하여, 특정 환경에서 학습된 모델은 새로운 작전 해역에서 성능이 저하될 가능성이 높다.

결과적으로, 풍부한 unlabeled 데이터와 희소한 전문가 라벨링 데이터 사이의 극명한 비대칭성은 기존 지도 학습(supervised learning) 방식의 성능 향상을 저해하는 결정적인 병목 현상으로 작용한다.

이러한 한계를 극복하기 위해 본 연구에서는 자기지도 학습을 도입하였다. 자기지도 학습은 라벨 없는 방대한 시퀀스로부터 데이터 자체의 구조적 특징을 학습함으로써,

탐지 파이프라인 전반의 라벨 의존성을 획기적으로 낮출 수 있는 효율적인 대안이다.

본 장에서 제안하는 접근 방식은 고도의 전문성이 요구되는 어노테이션 공수를 절감하여 데이터 수집부터 실전 배치까지의 소요 시간을 단축할 수 있다. 또한, 새로운 작전 지역에 시스템을 적용할 때 해당 지역의 unlabeled 데이터를 활용해 최소한의 추가 라벨링만으로도 신속하게 최적의 성능을 확보할 수 있는 환경 적응성을 제공한다.

2. Proposed Methods

본 연구에서는 수동 설계 특징의 한계를 극복하고 라벨 데이터에 대한 의존도를 낮추기 위해, 사전학습 및 미세조정으로 구성된 프레임워크를 제안한다. 본 방법론의 핵심은 방대한 양의 unlabeled 데이터 영상을 활용하여, backbone 네트워크가 레이더 비디오 도메인에 특화된 강건하고 범용적인 feature 표현을 학습하도록 초기화하는 것이다.

이를 위해 생성적 복원 기반의 MAE와 판별적 대조 기반의 SimCLR라는 두가지 상반된 자기지도 학습 패러다임을 적용하여, 해상 레이더 탐지에 가장 최적화된 표현 학습 방법을 제안한다. 이하에서는 각 모델의 세부 설계에 대해 기술한다.

2.1 Radar-Aware Masked AutoEncoder (RA-MAE)

RA-MAE는 국소적-전역적 공간 일관성을 최적화하는 생성적 자기지도 학습 패러다임에 기반한다. 레이더 비디오 객체 탐지에서 고강도 픽셀의 정밀한 공간적 배치는 정확한 바운딩 박스 위치 측정의 핵심 결정 요소이다. 본 연구에서는 마스크된 영역을 주변 맥락을 통해 복원하도록 강제하는 복원 목표가 타겟의 중심점과 경계를 정확히 식별하는 데 필수적인 레이더 신호의 고해상도 공간 세부 정보와 구조적 의존성을 보존할 것이라는 가설을 세웠다.

MAE 프레임워크를 레이더 도메인에 적응시키기 위해 두 가지 핵심 수정을 가하였다. 첫째로, 기존의 ViT 인코더를 YOLOv8s backbone으로 교체하여 다운스트림 탐지기와 구조적 동일성을 확보하였으며, 이를 통해 별도의 구조적 변환 레이어없이 사전학습 가중치를 전이할 수 있도록 하였다. 본 프레임워크는 크게 인코더, 블롭 우선 마스킹 모듈, 경량 MLP 디코더로 구성된다.

우선, 인코더는 YOLOv8s backbone의 초기 다섯 개 레이어로 구성되며, 입력 이미지를 640x640에서 80x80 크기의 128 채널 P3 특징 맵으로 다운 샘플링한다. 여기서, Adaptive Average Pooling을 통해 40x40 그리드로

축소된 후 flatten 하여 1600개의 128차원 패치 토큰 시퀀스로 변환하였다.

패치 토큰의 75%를 무작위 마스킹하는 기존 학습 방식과 달리, 본 연구에서는 레이더 반사 강도의 공간적 분포를 활용한 블롭 우선 마스킹 모듈을 도입하였다. 구체적으로, 확률 $p=0.2$ 로 전체 패치 중 상위 50%에 해당하는 밝은 패치를 후보군으로 설정하고, 이 중 전체 75%에 해당하는 1200개 마스크를 무작위로 선택하여 마스킹하였으며, 나머지 확률 0.8에 대해서는 위치에 관계없이 무작위 샘플링을 수행하였다. 여기서, 고강도 영역은 객체와 클러스터의 결정적인 식별 정보를 포함하므로, 이를 통해 인코더가 레이더 고유의 패턴에 최적화된 표현을 학습하도록 유도하였다. 마스킹된 패치 위치는 공유되는 학습 가능한 마스크 토큰으로 대체된다.

마지막으로, 디코더는 마스크된 16x16 패치의 원본 그레이 스케일 값을 복원하는 2층 MLP로 구현하였으며, 마스킹된 패치 위치에 대해서만 Mean Squared Error로 손실 함수를 계산하여 사전 학습을 수행하였다.

2.2 Radar-Specific SimCLR (RS-SimCLR)

이와 대조적으로, RS-SimCLR은 전역적 의미 불변성을 최적화하는 판별적 패러다임에 기반한다. 대조 학습을 통해 SimCLR은 동일한 레이더 프레임의 서로 다른 증강을 적용한 데이터를 하나의 임베딩으로 매핑하며, 이 과정에서 확률적 노이즈나 일시적인 신호 변동을 제거한다. 이러한 방식은 강건한 feature 표현을 학습함으로써 핵심적인 식별 특성을 포착하는 데 유리하다.

따라서, RS-SimCLR의 전역적 불변성과 RA-MAE의 국소적 복원 능력을 비교함으로써, 탐지 backbone이 전역적인 의미론적 표현과 세밀한 공간적 인식 중 어느 요소가 지배적인 영향을 미치는지 분석하고자 하였다.

대조 학습 목표를 레이더 도메인에 최적화하기 위해, 실제 신호 변동을 정밀하게 모사하는 증강 정책을 설계하였다. 일반적인 이미지 증강 기법 대신, X-band 레이더의 물리적 특성을 반영한 다음과 같은 변환을 적용하였다.

먼저, 공간적 불변성 확보를 위해 수평 및 수직 Flip ($p=0.5$)을 적용하였으며, 실제 레이더 비디오를 모사하기 위해 Intensity Jitter([0.6, 1.4], $p=1.0$) 및 가우시안 노이즈($\sigma=0.02$, $p=0.5$)를 추가하였으며, 거리에 따른 객체 크기 변화를 반영하기 위해 무작위 crop-resize(scale 0.7-1.0, $p=0.7$)를 적용하였다.

이러한 증강 기법을 동일한 이미지에 두 가지 증강을 독립적으로 적용하여 Positive Pair를 구성한다. 구성된 쌍




Fig. 4. Self-supervised Learning based Detection Framework: (Stage 1) Radar-aware MAE and Radar-Specific SimCLR Pre-training, (Stage 2) Supervised Fine-tuning

은 공유 가중치를 갖는 YOLOv8s 인코더를 통과하며, RA-MAE와 마찬가지로 P3 특징 맵에 Global Average Pooling을 적용하여 128차원의 표현 벡터를 추출한다. 이후, MLP 구조의 Projection Head를 통해 추출된 벡터를 대조 학습 공간으로 사상하여 NT-Xent 손실 함수를 최소화함으로써 임베딩 공간 내의 유사도를 최적화하였다.

2.3 Overall Framework

본 연구에서 제안한 자기지도 학습 프레임워크의 전체 구조는 Fig. 4와 같다. Stage 1은 unlabeled 데이터를 활용한 자기지도 사전학습 단계로, YOLOv8s의 Backbone을 인코더로 공유하며 두가지 상반된 패러다임을 병렬적으로 적용하였다. Stage 1.a에서는 RA-MAE를 통해 국소적 공간 일관성을 학습하였으며, Stage 1.b에서는 RS-SimCLR을 통해 전역적 의미 불변성을 학습하였다.

각 사전학습은 unlabeled 데이터에 대해 100 epoch 동안 수행되었으며, 이를 통해 라벨링 데이터 없이도 도메인에 특화된 강건한 feature 초기값을 확보하였다.

Stage 2는 labeled 데이터셋을 활용한 지도학습 기반 미세조정 단계이다. Stage 1에서 사전학습한 Backbone 가중치를 YOLOv8s 모델에 각각 주입하여, end-to-end 미세조정을 수행하였다. 이를 통해, 모델을 사전 학습된 범용 feature를 localization이라는 구체적인 task에 최적화하였다.

3. Experimental Setup

3.1 Pre-training and Fine-tuning Setup

사전학습은 탐지 해상도와 일치하는 640×640픽셀로 분할된 unlabeled 데이터 시퀀스를 대상으로 수행되었다. 학습은 AdamW Optimizer를 사용하였으며, 10 epoch의 warmup을 포함하여 총 100 epoch 동안 실행하였다. 각 모델의 세부 하이퍼 파라미터는 Table 6과 같다.

Table 6. Hyperparameters for Self-supervised Pre-training and Supervised Fine-tuning

Hyper parameter	RA-MAE	RS-SimCLR	Fine-tuning
Model	YOLOv8s (layers 0-9)	YOLOv8s (layers 0-9)	YOLOv8s
Optimizer	AdamW	AdamW	AdamW
Learning rate	1.5×10^{-4}	3×10^{-4}	1×10^{-3}
Batch size	64	128	32
LR Scheduler	Cosine + 10 epochs warmup	Cosine + 10 epochs warmup	Cosine + 3 epochs warmup

이후 진행된 미세조정 단계에서는 labeled 데이터셋을 활용하여 전체 YOLOv8s 모델을 학습하였다. 사전학습 단계와 동일하게 AdamW Optimizer를 사용하였으며, 3 epoch의 warmup을 포함한 100 epoch 동안 학습을 수행하였다. 이 과정에서 학습률(Learning Rate)을 1×10^{-3} 으로 조정하여, 사전학습된 가중치가 탐지 Task에 효율적으로 적응하도록 하였다.

3.2 Labeled Data Subset Construction

라벨 데이터 효율성을 평가하기 위해, 전체 라벨 데이터셋(15,872 프레임)의 10%, 25%, 50%, 100% 비율에 해당하는 네 가지 하위 집합을 구성하였다. 각 하위 집합이 기존 데이터셋의 시계열 및 공간 분포를 보존하기 위해, 학습 데이터셋에서 stratified random 샘플링을 통해 하위 집합을 구성하였다.

3.3 Statistical Significance Verification

모델 성능 검증 간 우연성에 의한 변동성을 배제하고 통계적 엄밀성을 확보하기 위해, 각 비교 항목에 대한 통계 검정을 적용하였다.

먼저, 동일 테스트 이미지에 대한 비교가 가능한 경우 paired bootstrap ($n=2,000$)을 통해 mAP_{50} 차이에 대한 95% 신뢰구간(CI, Confidence Interval)을 산출하였다. 이때, 신뢰구간이 0을 포함하지 않는 경우 통계적으로 유의한 차이가 있다고 판단하였다.

또한, 고정된 단일 신뢰도 임계값 설정에 따른 결과의 의존성을 배제하기 위해 임계값 재보정 절차를 적용하였다. 각 라벨 비율에서 scratch 모델의 recall (conf=0.25)을 기준으로 고정하고, recall을 유지하면서도 FP가 가장 낮은 confidence 임계값을 탐색하여 FP를 비교하였다.

4. Results

모든 실험 조건에 대한 종합적인 성능 결과는 Table 7과 같다. 분석 결과, RA-MAE는 모든 라벨 비율에서 mAP_{50} 및 mAP_{50-95} 지표 모두 Scratch 기반 모델과 RS-SimCLR 모델을 일관되게 능가하는 성능을 보였다.

특히, 라벨이 극도로 부족한 상황(10%)에서 RA-MAE는 0.6280의 mAP_{50} 을 달성하여, Scratch Baseline(0.6038) 대비 높은 성능 하한선을 구축하였다. 이는 RA-MAE 사전 학습 단계가 극소량의 라벨 데이터만으로도 모델이 더 높은 성능 수준으로 수렴할 수 있게 함을 입증한다.

Scratch baseline 대비 방법별 성능 향상 정도를 정량적으로 분석한 결과, $mAP_{50}(\Delta=+0.0426)$ $mAP_{50-95}(\Delta=+0.043)$ 의 최대 향상은 50% 라벨 비율을 사용한 RA-MAE에서 관찰되었다. 이는 사전학습된 가중치가 50%의 라벨 데이터 학습 신호와 결합하였을 때 가장 효율적인 성능 향상을 유도함을 의미한다.

특히, 주목할 점은 저라벨 구간에서의 FP 억제 효과이다. 10% 라벨 비율에서 RA-MAE는 Recall을 유지($\Delta=+0.0041$)하면서도 FP를 213개(-9.2%) 감소시키는 성과를 보였다. 이는 매우 제한적인 지도 학습 환경에서도 사전학습된 표현이 객체와 Hard Negative를 구분할 수 있는 최적의 초기 feature 공간을 제공함으로써, 탐지기의 정밀도를 실질적으로 향상시켰음을 시사한다.

이어서, Table 8은 블롭 우선 마스킹 비율에 따른 모델 성능(mAP_{50-95}) 비교 결과를 나타낸다. 여기서 r 은 블롭 우선 마스킹 확률을 의미하며, $r=0.00$ 은 완전 무작위 마스킹, $r=1.00$ 은 완전 블롭 우선 마스킹에 해당한다.

실험 결과 모든 라벨 비율 구간에서 $r=0.20$ 이 최고 성능을 기록했으며, 특히 저라벨 구간 (10%, 25%)에서 무작위 마스킹 대비 각각 0.027, 0.037 향상되었다.

한편, $r=0.20$ 을 초과하여 증가할수록 성능은 감소하거나 정체되는 경향을 보였다. 완전 블롭 우선($r=1.00$) 조건에서도 무작위 마스킹($r=0.00$) 대비 우수한 성능을 보였으나, 결과적으로 전체 마스킹의 20%에 블롭 우선 전략을 적용하는 것이 가장 유효함을 확인하였다.

Table 8. Performance Comparison by BPM Random-blob Prior Masked Ratio (r) - mAP_{50-95} .

Labeled Ratio	$r=0.00$	$r=0.20$	$r=0.40$	$r=0.60$	$r=0.80$	$r=1.00$
10%	0.5160	0.5433	0.5354	0.5358	0.5377	0.5417
25%	0.5863	0.6230	0.6129	0.5718	0.6016	0.6023
50%	0.6472	0.6507	0.6128	0.6261	0.6429	0.6490
100%	0.6462	0.6563	0.6426	0.6534	0.6394	0.6496

Table 7. Comprehensive Performance Comparison of Detection Models across Different Labeled Ratios

Labeled Ratio	Training Samples	Method	mAP_{50}	mAP_{50-95}	Precision	Recall	F1-score	TP	FP	FN
10%	1,587	Scratch	0.6038	0.5217	0.4794	0.7338	0.5799	2131	2314	773
		RS-SimCLR	0.6064	0.5183	0.4409	0.7348	0.5511	2134	2706	770
		RA-MAE	0.6280	0.5433	0.5049	0.7379	0.5996	2143	2101	761
25%	3,968	Scratch	0.6845	0.6039	0.5835	0.7042	0.6382	2045	1460	859
		RS-SimCLR	0.6174	0.5355	0.5473	0.6636	0.5998	1927	1594	977
		RA-MAE	0.7118	0.6230	0.5800	0.7476	0.6532	2171	1572	733
50%	7,936	Scratch	0.7004	0.6077	0.6215	0.6915	0.6546	2008	1223	896
		RS-SimCLR	0.7035	0.6175	0.6329	0.6897	0.6601	2003	1162	901
		RA-MAE	0.7430	0.6507	0.6064	0.7455	0.6688	2165	1405	739
100%	15,872	Scratch	0.7385	0.6509	0.6529	0.7211	0.6853	2094	1113	810
		RS-SimCLR	0.7203	0.6307	0.6267	0.7262	0.6728	2109	1256	795
		RA-MAE	0.7394	0.6563	0.6347	0.7376	0.6823	2142	1233	762

Table 9. Statistical Significance Verification and FP/Image Comparison at Fixed Recall (Baseline: Scratch, conf=0.25). **Bold** indicates statistical significance (95% CI excludes 0), negative Δ (FP/image) indicates improvement.

Comparison	Labeled Ratio	mAP ₅₀ Δ [95% CI]	Fixed-Recall	Scratch FP/image	Calibrated Threshold	Calibrated FP/image	Δ (FP/image)
Scratch vs. RA-MAE	10%	+0.0195 [+0.0101,+0.0291]	0.7338	0.4383	0.2598	0.3903	-0.0479
	25%	+0.0268 [+0.0184,+0.0355]	0.7042	0.2765	0.3603	0.2227	-0.0538
	50%	+0.0441 [+0.0357,+0.0529]	0.6915	0.2316	0.3862	0.1741	-0.0576
	100%	-0.0087 [-0.0149, -0.0024]	0.7211	0.2108	0.2923	0.2072	-0.0036
Scratch vs. RS-SimCLR	10%	-0.0109 [-0.0233,+0.0015]	0.7348	0.5125	0.2465	0.4409	-0.0072
	25%	+0.0672 [+0.0559,+0.0783]	0.6636	0.3019	0.3364	0.2201	-0.0818
	50%	-0.0086 [-0.0179,+0.0005]	0.6897	0.2201	0.2556	0.2292	+0.0091
	100%	+0.0252 [+0.0173,+0.0336]	0.7262	0.2379	0.2389	0.2174	-0.0205

통계적 유의성 검증 및 임계값 재보정 결과는 Table 9와 같다. Paired bootstrap 분석 결과, RA-MAE는 10%, 25%, 50% 라벨 구간에서 Scratch 대비 mAP50이 유의한 우위를 보였으나, 100% 구간에서는 소폭 감소하였다($\Delta = -0.0087$). RS-SimCLR는 일부 구간에서 유의한 차이를 보였으나 일관된 우위 경향은 관찰되지 않았다.

이에 각 모델의 Recall을 Scratch의 기준 운용점 (conf=0.25)으로 고정하여 FP를 비교한 결과, RA-MAE는 모든 라벨 비율 구간에서 FP/image가 감소하였다. 특히, 100% 라벨 구간에서도 FP/image가 -0.036 개선되어, 탐지 신뢰도 측면에서의 이점을 확인하였다.

탐지 성능을 정성적으로 검증하기 위해, 두 가지 대표적인 시나리오에 대하여 Scratch 기준 모델, RS-SimCLR, RA-MAE의 추론 결과를 비교 분석하였다(Fig. 5). Fig. 5. (A)의 경우, 복잡한 클러스터 내에 다수의 소형 표적이 존재하는 환경으로, Scratch 모델은 표적이 실제로는 존재하나 탐지하지 못하는 미탐지(False Negative)가 발생하였으며, RS-SimCLR은 누락된 표적을 복구하였으나 동시에 오탐지를 발생시키는 한계를 보였다. 반면, RA-MAE는 오탐 및 미탐없이 표적을 정확히 탐지함으로써, 탐지 민감도와 정밀도 사이의 개선된 균형을 보였다.

Fig. 5. (B)의 경우, III장에서 논의한 물리적 동등성으로 인해 실제 표적과 유사한 강도 및 공간 스케일을 갖는 ‘객체 유사’ 클러스터가 포함되어 있다. Scratch와 RS-SimCLR 모델은 이러한 고강도 블롭을 표적으로 오인하여 FP를 생성하였으나, RA-MAE는 재현율을 유지하면서도 이러한 허위 탐지를 효과적으로 억제한 것을 볼 수 있다. 이는 BPM 모듈이 인코더가 변별력 있는 구조적 패

턴을 학습하도록 유도함으로써, 해상 레이더 영상의 특징인 신호의 구별 불가능성을 완화하는 데 기여한 것으로 분석된다.




Fig. 5. Qualitative Comparison for Detection Results. (A) Case 1: Multiple Targets, (B) Case 2: Object-like Clutter. Colored Boxes: True Positives(Sky blue), False Positives (Orange), False Negatives(Purple).

5. Analysis

5.1 Label Efficiency Under Annotation Scarcity

실험 결과, RA-MAE는 모든 라벨 비율에서 일관된 성능 향상을 기록하였다. Fig. 6의 라벨 비율에 따른 성능 변화 추이를 살펴보면, RA-MAE는 저라벨 구간(25-50%)에서 Scratch 모델 대비 가장 가파른 성능 상승 곡선을 그리며 우수한 라벨 효율성을 입증한다. 특히 mAP₅₀과 mAP₅₀₋₉₅ 모두에서 RA-MAE가 높은 성능을 기록하였으며, 이는 사전학습이 객체 탐지 및 정밀한 위치 추정 성능을 동시에 향상시켰음을 보여준다.




Fig. 6. Analysis of Performance Metrics across Labeled Data Ratios: mAP₅₀, mAP₅₀₋₉₅, Recall and FP/Image

특히, 10% 라벨 비율에서의 FP 감소 측면을 보면, RA-MAE는 Recall을 유지($\Delta=+0.0041$)하면서도 FP를 213개(-9.2%) 감소시켰다. 또한 'FP/Image vs. Labeled Ratio' 그래프에서 확인되듯이, RA-MAE는 10% 라벨 비율에서 가장 낮은 FP/image 값을 기록하였다. 이러한 FP 억제 효과는 unlabeled 데이터를 활용한 feature 초기화 단계에서 달성된 결과이며, 제안된 방법론이 운용 환경의 FP 문제를 해결할 수 있는 실질적인 방안을 입증한다.

라벨 효율성을 분석한 결과, 25% 라벨을 사용한 RA-MAE(mAP₅₀=0.7118)가 50% 라벨을 사용한 Scratch Baseline(mAP₅₀=0.7004)보다 높은 성능을 보였다. 이는 추가적인 라벨링 없이 사전학습만으로 성능이 향상되었으며, 저라벨 상황에서 모델이 겪는 초기 수렴 문제를 자기 지도 학습이 효과적으로 보완했음을 의미한다.

마지막으로, 지도학습 데이터가 부족한 상황에서도 RA-MAE는 안정적인 FP-Recall 트레이드 오프를 유지하였다. 10% RA-MAE 모델이 동일 조건의 Scratch 모델보다 FP 감소와 Recall 향상 모두에서 우위를 점한 것은, 사전학습 단계에서 데이터의 일반적인 특성을 미리 학습했기 때문이다. 결과적으로 unlabeled 데이터로부터 학습된 표현이 저라벨 환경의 과적합 현상을 억제하고, 모델이 더 강건한 결정 경계로 수렴하도록 유도했음을 보여준다.

5.2 Spatial Reconstruction & Semantic Invariance

실험 결과, 모든 라벨 비율에서 RA-MAE가 RS-SimCLR보다 일관되게 우수한 성능을 보였다. 이러한 성능 차이는 “공간적 복원”과 “의미론적 불변성”이라는 두 학습 목표가 갖는 본질적인 특성 차이에서 기인한다.

객체 탐지는 표적의 존재 여부를 판별하는 분류 작업뿐만 아니라, 바운딩 박스의 좌표를 예측하는 회귀 작업이 동시에 수행되어야 하므로 세밀한 공간 정보가 필수적이다. 특히 객체 경계의 국소적 구조와 급격한 강도 변화를 보존하는 것이 탐지 성능의 결정 요인이 된다. RA-MAE는 BPM 전략을 통해 모델이 마스크된 영역을 복구하는 과정

에서 이러한 세밀한 공간적 의존성을 학습한다. 결과적으로 레이더 블롭의 정밀한 형태학적 특성에 최적화된 표현을 학습함으로써, 미세조정 단계에서 정확한 위치 추정을 수행한 것으로 분석된다.

반면, RS-SimCLR는 전역적 불변성을 최적화하는 판별적 패러다임을 따른다. 증강으로 인해 변형된 이미지라도 동일한 객체라면 하나의 임베딩으로 매핑하는 방식은 노이즈 제거와 본질적인 특성 학습에 유리하여 이미지 분류에는 효과적이다. 그러나 탐지 관점에서는 불변성을 극대화하는 과정에서 레이더 비디오의 정밀한 경계와 같은 세부 공간 정보가 오히려 소실되는 부작용이 발생한다.

이러한 분석은 mAP₅₀과 mAP₅₀₋₉₅의 성능 격차를 통해 입증된다. RS-SimCLR은 객체의 존재 유무를 판단하는 mAP₅₀에서는 Scratch baseline과 유사한 성능을 보였으나, 정밀한 예측을 요구하는 mAP₅₀₋₉₅에서는 RA-MAE보다 낮은 성능을 보였다. 이는 RS-SimCLR이 객체의 존재 자체는 인식하지만, 정밀한 바운딩 박스 예측에 필요한 국소적 공간 정밀도를 손실했음을 의미한다.

결론적으로, 레이더 탐지 성능을 극대화하기 위해서는 전역적인 의미론적 불변성보다 국소적인 공간 세부 정보를 복원하는 능력이 지배적인 영향을 미침을 확인하였다.

5.3 Analysis of Label Efficiency and Label Regime via Performance Convergence

RA-MAE에 의한 mAP₅₀ 향상 폭은 라벨 비율이 증가함에 따라 10% 라벨 대비 25% 라벨에서 0.0838 향상, 25% 라벨 대비 50% 라벨에서 0.0312 향상을 보였으나, 50% 라벨 대비 100% 라벨에서 성능이 감소하는 포화 및 역전 현상을 보였다(Table 7).

이러한 현상은 Table 9의 고정 임계값 (conf=0.25) 기준으로 수행한 성능 비교의 한계와 대응된다. RA-MAE와 Scratch는 서로 다른 confidence 분포를 형성하므로, 고정 임계값 비교는 실제 성능 차이를 완전히 반영하지 못한다. Fixed Recall 보정 적용 시, 100% 라벨 구간에서

mAP₅₀은 낮았으나, FP/image는 -0.0036으로 개선되었다. 이는 고정 임계값 기준의 역전이 성능 저하가 아닌 confidence 보정 지점의 차이에서 기인함을 나타낸다.

종합하면, 자가지도 사전학습의 이득은 라벨 비율 증가에 따라 수렴하며, 고정 임계값 기준에서는 100% 라벨 구간에서 역전으로 관측되나 confidence 임계값 보정 시 이득이 유지된다. 이는 라벨링 자원이 충분한 환경에서도 사전학습 모델의 잠재적 이득을 완전히 활용하기 위해 임계값 재보정이 중요함을 시사한다. 특히, 사전 학습으로 인한 성능 향상 폭이 감소하는 고라벨 구간에서 추가 학습 비용없이 모델의 신뢰도를 보완할 수 있는 효과적인 방법으로 고려할 수 있다.

6. Summary

본 장에서는 수동 설계 특징 기반의 FP 역제가 가진 성능 상한선을 극복하고, 함정 전투체계에서 수집되는 방대한 양의 unlabeled 데이터를 효과적으로 활용할 수 있는 자가지도 학습 기반의 프레임워크를 제안하였다.

먼저, 생성적 복원 기반의 RA-MAE와 판별적 대조 기반의 RS-SimCLR를 통해 레이더 도메인에 최적화된 표현 학습 방법을 비교 분석하였다. 실험 결과, RA-MAE는 모든 라벨 비율에서 우수한 성능을 기록하였으며, 특히 BPM 모듈이 레이더 신호의 특성을 효과적으로 보존함으로써, 정밀한 위치 추정을 가능하게 했음을 입증하였다.

또한, 라벨링 데이터가 극도로 부족한 저라벨 구간에서 RA-MAE의 효용성이 극대화됨을 확인하였다. 특히, 10%의 라벨만으로도 Scratch baseline 대비 유의미한 FP 감소와 Recall 향상을 달성한 것은, 사전학습 단계에서 확보된 초기 feature가 라벨의 부족함을 보완하여 최적의 결정 경계로 수렴하도록 유도했음을 시사한다.

결과적으로 자가지도 학습이 지도학습을 완전히 대체할 수는 없으나, 라벨링 데이터가 희소한 환경에서 모델의 수렴을 가속화함을 확인하였다. 특히 라벨링 비용이 극도로 높은 함정 전투체계에서, 소량의 라벨 데이터만으로도 최적 성능에 근접한 결과를 얻은 것은 실무적으로 큰 가치를 지닌다. 이는 RA-MAE가 전문가 어노테이션에 대한 의존도를 낮춤으로써, 새로운 작전 지역의 unlabeled 데이터를 활용해 모델을 신속하게 최적화할 수 있는 환경 적응성을 제공할 수 있음을 입증한 결과이다.

V. Conclusions

본 연구는 데이터 희소 환경에서 레이더 탐지가 직면한 기술적 한계를 분석하고, 이를 극복하기 위한 방법론적 대안을 제시하였다. 단일 프레임 기반의 수동 설계 특징의 판별력 한계를 정량적으로 규명하고, 이를 보완하는 자가지도 표현학습의 효용성을 입증함으로써 제한된 라벨링 자원에서 최적의 탐지 성능을 달성하는 방안을 도출하였다.

분석 결과, 해상 레이더의 사후 FP 역제는 성능 상한선에 의해 제한됨을 실증하였다. 객체와 클러스터 간의 강도 분포가 통계적으로 구별 불가능하다는 점은 통계 분석을 넘어 ML 분류기에서도 일관되게 관찰되었으며, 이는 수동 특징 추출 정보만으로는 객체와 클러스터를 완전히 분리할 수 없다는 특성에서 기인한 것임을 의미한다. 이에 본 연구에서는 사후 필터링의 한계를 명시하고, 탐지 모델의 표현력을 강화하는 접근법으로의 전환을 제시하였다.

이를 극복하기 위한 대안으로 도입된 도메인 적응형 자가지도 사전학습의 효용성을 확인하였다. 특히 RA-MAE는 블롭 우선 마스킹을 통해 레이더 신호의 고강도 영역에 특화된 표현을 학습하였으며, 모든 라벨 비율에서 일관된 성능 향상을 보였다. 특히, 저라벨 구간에서 가장 큰 성능 개선을 보였으며, 이는 unlabeled 데이터를 활용한 사전학습이 labeled 데이터가 희소한 환경에서도 유효한 탐지 성능을 확보할 수 있는 전략임을 입증한다.

그러나 사전학습에 활용된 unlabeled 시퀀스의 다양성 부족으로 인해 다양한 해상 상태나 지형적 특성에 따른 클러스터 표현이 충분히 반영되지 않았을 가능성이 존재한다. 또한, 10% 라벨을 사용한 RA-MAE의 이미지 당 FP 발생 비율이 0.3979로, 100% 라벨에서의 Scratch(0.2108) 대비 높은 수준이다. 이는 저라벨 환경에서의 성능 향상에도 불구하고, 실제 운용 시 운용자의 부하를 증가시킬 수 있는 현실적 한계로 작용한다. 따라서 임계값 재보정과 같은 사후 조정을 병행하여 운용 효율성을 확보하는 전략이 필요함을 시사한다.

따라서 향후 연구에서는 다양한 작전 지역의 데이터로 확장하여 학습된 표현의 일반화 성능을 극대화하고자 한다. 동시에, 학습 후 신뢰도 임계값 보정 및 손실 함수 개선을 통해 Recall과 Precision의 최적 균형점을 확보할 예정이다. 이러한 단계적 고도화를 통해, 신뢰성 있고 강한 레이더 탐지 프레임워크를 구축하고자 한다.

ACKNOWLEDGEMENT

This work was supported by Korea Research Institute for defense Technology planning and advancement (KRIT) - Grant funded by Defense Acquisition Program Administration (DAPA) (KRIT-CT-23-030)

REFERENCES

- [1] M. I. Skolnik, "Radar handbook," IEEE Aerospace Electronic Systems Magazine, Vol. 23, No. 5, pp. 41-41, 2008.
- [2] K. D. Ward, S. Watts, and R. J. Tough, "Sea clutter scattering, the K distribution and radar performance," IET, Vol. 20, 2006.
- [3] H. Rohling, "Radar CFAR thresholding in clutter and multiple target situations," IEEE Transactions on aerospace and electronic systems, Vol. 19, No. 4, pp. 608-621, 1983. DOI: 10.1109/TAES.1983.309350
- [4] M. Weiss, "Analysis of some modified cell-averaging CFAR processors in multiple-target situations," IEEE Transactions on Aerospace and Electronic Systems, Vol. 18, No. 1, pp. 102-114, 1982. DOI: 10.1109/TAES.1982.309210
- [5] P. L. Shui, D. C. Li, and S. W. Xu, "Tri-feature-based detection of floating small targets in sea clutter," IEEE Transactions on Aerospace and Electronic Systems, Vol. 50, No. 2, pp. 1416-1430, 2014. DOI: 10.1109/TAES.2014.120657
- [6] X. Chen, N. Su, Y. Huang, and J. Guan, "False-alarm-controllable radar detection for marine target based on multi features fusion via CNNs," IEEE Sensors Journal, Vol. 21, No. 7, pp. 9099-9111, 2021. DOI: 10.1109/JSEN.2021.3054744
- [7] S. Xia, Y. Kong, K. Xiong, and G. Cui, "Target detection in sea clutter via contrastive learning," IEEE Transactions on Instrumentation and Measurement, Vol. 72, pp. 1-13, 2023. DOI: 10.1109/TIM.2023.3288254
- [8] Z. Baird, M. K. McDonald, S. Rajan, and S. J. Lee, "A CNN-LSTM network for augmenting target detection in real maritime wide area surveillance radar data," IEEE Access, Vol. 8, pp. 179281-179294, 2020. DOI: 10.1109/ACCESS.2020.3025144
- [9] Q. Qu, Y. L. Wang, W. Liu, and B. Li, "A false alarm controllable detection method based on CNN for sea-surface small targets," IEEE Geoscience and Remote Sensing Letters, Vol. 19, pp. 1-5, 2022. DOI: 10.1109/LGRS.2022.3190865
- [10] J. Wang and S. Li, "Maritime radar target detection in sea clutter based on CNN with dual-perspective attention," IEEE Geoscience and Remote Sensing Letters, Vol. 20, pp. 1-5, 2022. DOI: 10.1109/LGRS.2022.3230443
- [11] S. Xu, H. Ru, D. Li, P. Shui, and J. Xue, "Marine radar small target classification based on block-whitened time-frequency spectrogram and pre-trained CNN," IEEE Transactions on Geoscience and Remote Sensing, Vol. 61, pp. 1-11, 2023. DOI: 10.1109/TGRS.2023.3240693
- [12] J. Gui, T. Chen, J. Zhang, Q. Cao, Z. Sun, H. Luo, and D. Tao, "A survey on self-supervised learning: Algorithms, applications, and future trends," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 46, No. 12, pp. 9052-9071, 2024. DOI: 10.1109/TPAMI.2024.3415112
- [13] T. Chen, S. Kornblith, M. Norouzi, and G. Hinton, "A simple framework for contrastive learning of visual representations," International conference on machine learning, pp. 1597-1607, November 2020. DOI: 10.5555/3524938.3525087
- [14] K. He, H. Fan, Y. Wu, S. Xie, and R. Girshick, "Momentum contrast for unsupervised visual representation learning," Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, pp. 9729-9738, 2020. DOI: 10.1109/CVPR.42600.2020.00975
- [15] J. B. Grill, F. Strub, F. Altche, C. Tallec, P. Richemond, E. Buchatskaya, and M. Valko, "Bootstrap your own latent-a new approach to self-supervised learning," Advances in neural information processing systems, Vol. 33, pp. 21271-21284, 2020. DOI: 10.5555/3495724.3497510
- [16] M. Caron, H. Touvron, I. Misra, H. Jegou, J. Mairal, P. Bojanowski, and A. Joulin, "Emerging properties in self-supervised vision transformers," Proceedings of the IEEE/CVF international conference on computer vision, pp. 9650-9660, 2021. DOI: 10.1109/ICCV48922.2021.00951
- [17] H. Bao, L. Dong, S. Piao, and F. Wei, "Beit: Bert pre-training of image transformers," arXiv preprint arXiv:2106.08254, 2021.
- [18] J. Devlin, M. W. Chang, K. Lee, and K. Toutanova, "Bert: Pre-training of deep bidirectional transformers for language understanding," Proceedings of the 2019 conference of the North American chapter of the association for computational linguistics: human language technologies, Vol. 1, pp. 4171-4186, June 2019. DOI: 10.18653/v1/N19-1423
- [19] K. He, X. Chen, S. Xie, Y. Li, P. Dollar, and R. Girshick, "Masked autoencoders are scalable vision learners," Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, pp. 16000-16009, 2022. DOI: 10.1109/CVPR52688.2022.01553
- [20] O. Manas, A. Lacoste, X. Giro-i-Nieto, D. Vazquez, and P. Rodriguez, "Seasonal contrast: Unsupervised pre-training from uncurated remote sensing data," Proceedings of the IEEE/CVF international conference on computer vision, pp. 9414-9423, 2021. DOI: 10.1109/ICCV48922.2021.00928
- [21] X. Sun, P. Wang, W. Lu, Z. Zhu, X. Lu, Q. He, and K. Fu, "RingMo: A remote sensing foundation model with masked image modeling," IEEE Transactions on Geoscience and Remote

- Sensing, Vol. 61, pp. 1-22, 2022. DOI: 10.1109/TGRS.2022.3194732
- [22] W. Li, W. Yang, T. Liu, Y. Hou, Y. Li, Z. Liu, and L. Liu, "Predicting gradient is better: Exploring self-supervised learning for SAR ATR with a joint-embedding predictive architecture," *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 218, pp. 326-338, 2024. DOI: 10.1016/j.isprsjprs.2024.09.013
- [23] P. Zhou, B. Niu, L. Huang, Q. Wang, Y. Zhao, G. Zhou, and Y. Hu, "SARDet-MIM: Enhancing SAR Target Detection via a Structural and Scattering Masked Autoencoder," *Remote Sensing*, Vol. 18, No. 4, pp. 580, 2026. DOI: 10.3390/rs18040580
- [24] L. Si, G. Li, C. Zheng, and F. Xu, "Self-supervised representation learning for the object detection of marine radar," *Proceedings of the 8th International Conference on Computing and Artificial Intelligence*, pp. 751-760, March 2022. DOI: 10.1145/3532213.3532328
- [25] J. Wang and S. Li, "Maritime radar target detection model self-evolution based on semisupervised learning," *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 62, pp. 1-11, 2023. DOI: 10.1109/TGRS.2023.3343416
- [26] K. Sohn, Z. Zhang, C. L. Li, H. Zhang, C. Y. Lee, and T. Pfister, "A simple semi-supervised learning framework for object detection," *arXiv preprint arXiv:2005.04757*, 2020.
- [27] Z. Huang, S. Denman, A. Pemasiri, C. Fookes, and T. Martin, "Radar signal recognition through self-supervised learning and domain adaptation," *arXiv preprint arXiv: 2501.03461*, 2025.
- [28] Y. C. Liu, C. Y. Ma, Z. He, C. W. Kuo, K. Chen, P. Zhang, and P. Vajda, "Unbiased teacher for semi-supervised object detection," *arXiv preprint arXiv:2102.09480*, 2021.
- [29] C. C. Kao, T. Y. Lee, P. Sen, and M. Y. Liu, "Localization-aware active learning for object detection," *Asian Conference on Computer Vision*, pp. 506-522, Cham, Switzerland, December 2018. DOI: 10.1007/978-3-030-20876-9_32
- [30] T. Yuan, F. Wan, M. Fu, J. Liu, S. Xu, X. Ji, and Q. Ye, "Multiple instance active learning for object detection," *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 5330-5339, 2021. DOI: 10.1109/CVPR46437.2021.00529
- [31] Y. Li, H. Mao, R. Girshick, and K. He, "Exploring plain vision transformer backbones for object detection," *European conference on computer vision*, pp. 280-296, Cham, Switzerland, October 2022. DOI: 10.1007/978-3-031-20077-9_17
- [32] H. Jang, W. Yang, H. Kim, D. Lee, Y. Kim, J. Park, and A. Kim, "MOANA: Multi-radar dataset for maritime odometry and autonomous navigation application," *The International Journal of Robotics Research*, Vol. 45, No. 2, pp. 193-203, 2026. DOI: 10.1177/02783649251354897
- [33] Ultralytics, "YOLOv8," <https://github.com/ultralytics/ultralytics>.
- [34] I. Loshchilov and F. Hutter, "Decoupled weight decay regularization," *arXiv preprint arXiv:1711.05101*, 2017. DOI: 10.48550/arXiv.1711.05101
- [35] T. Hastie, "The elements of statistical learning: data mining, inference, and prediction," 2009.

Authors



Ju-Mi Park received the B.S degree in Division of Media, Culture and Design Technology from Hanyang University ERICA, South Korea and the M.S. degree in School of Integrated Technology from Gwangju

Institute of Science and Technology. She is currently working in Hanwha Systems Co. from 2023. She is interested in Intelligent Naval Combat System using Artificial Intelligence.



Da-Huin Moon received the B.S. degree in Electronic System Engineering from Hanyang University ERICA, South Korea and the M.S. degree in Electronic Engineering from Hanyang University, South Korea.

She is currently with Hanwha Systems Co. from 2019. Her research interests include Naval Combat Management System, Radar Video, Convolution Neural Network and Automatic Test Case Generation.



Hyeon-Mo Kim received the B.S. and M.S. degrees in Computer Science and Engineering from Sejong University, South Korea, in 2022 and 2024. He is currently with Hanwha Systems Co. from 2024.

His research interests include Intelligent Naval Combat Management System, Command Decision Support, Knowledge Base, Large Language Model, RAG, Ontology Engineering.



Woo-Hyeon Moon received the B.S. degree in Electronic Engineering from Jeonbuk National University and M.S. degree in Artificial Intelligence(Reinforcement Learning, Natural Language Processing)-based Robotics

from Korea Advanced Institute of Science and Technology, South Korea, in 2022 and 2024. He is currently with Hanwha Systems Co. from 2024. His research interests include Intelligent Combat Management System, Reinforcement Learning, Multi-Agent Reinforcement Learning, Natural Language Processing, Knowledge Base, Large Language Model, and Artificial Intelligence.



Seo-Ho Lee received the B.S. degree in Mechanical Engineering and Unmanned Vehicle Engineering from Sejong University, Korea, in 2022, and the M.S. degree in Intelligent Mechatronics from Sejong

University, Korea, in 2024. He is currently with Hanwha Systems Co. from 2024. His research interests include Intelligent Naval Combat Management System, Control Engineering, Command Decision Support and Reinforcement Learning.



Hyo-Jo Lee received B.S degree in Electronics & Computer Science in from Kyungpook National University, Korea. He is currently working in Hanwha Systems Co. from 2010. He is interested in Intelligent

Naval Combat Management System using Artificial Intelligence, Command Decision Support and Data Link.



Won-Seok Jang received M.S degree in Computer Engineering from Chungnam National University, South Korea and completed Ph.D. program from Kyungpook National University, Korea.

He is currently working in Hanwha Systems Co. from 2017. He is interested in Intelligent Naval Combat Management System using Artificial Intelligence, Naval Unmanned System and Naval Safety System.



Ji-Seok Yoon received the B.S degree in Electronic Engineering from Kumoh National Institute of Technology, South Korea, in 2012, and the M.S. and Ph.D. degrees in mechatronics from Gwangju Institute of

Science and Technology, Gwangju, South Korea, in 2014 and 2021. From 2021 to 2023, Ji-Seok Yoon was a Postdoctoral Researcher with the Vision and Image Processing Laboratory, Tech University of Korea. Since 2023, he has been the CTO of IKLAB Inc. Currently, he is working in Hanwha Systems Co. from 2023. He is interested in Intelligent Naval Combat Management System using Artificial Intelligence, Command Decision Support, Image Processing, Natural Language Processing, Data Processing, Digital Twin and Generative AI.