

A Study on Deep Learning-based Automatic Target Recognition System in IR Image for Intelligent Combat Management System

Gyu-Seok Do*, Ju-Mi Park*, Won-Seok Jang*, Young-Sub Yang*, Ji-Seok Yoon*

*Engineer, Naval R&D Center, Hanwha Systems, Pangyo, Korea

[Abstract]

In this paper, we propose a system that can automatically recognize targets using infrared (IR) images from an electro-optical tracking system (EOTS) for an intelligent combat management system (CMS). Target detection through IR images is the best method in low-light environments at night for military purposes. However, IR images are relatively inferior to optical images and lack of texture information, making it difficult for CMS operators to recognize targets because there are few feature points that can be tracked. To solve this problem, this study proposes an automatic target recognition (ATR) system based on a deep learning model optimized for the IR operation environment of EOTS. First, transfer learning was employed to ensure the model's generalization performance, and data augmentation techniques were applied to IR images to reflect elements occurring in battlefield scenarios. Additionally, model ensemble methods were utilized to enhance target recognition rates, resulting in the design of an AI model suitable for naval combat systems. As a result of quantitative analysis, the proposed method demonstrated excellent performance with an accuracy of 92% for various anti-air and anti-ship targets. Therefore, it is expected to be used as an elementary technology for intelligent CMS.

▶ **Key words:** Intelligent Combat Management System, EOTS, IR, ATR, Deep Learning, Model Ensemble

[요약]

본 논문에서는 지능형 함정전투체계를 위한 함정용 전자광학추적장비(EOTS; Electro-Optical Targeting System)의 적외선(IR; InfraRed) 이미지의 표적을 자동으로 인식할 수 있는 시스템을 제안한다. 군사적 목적으로 광량이 부족한 야간 환경에서는 IR 이미지를 통한 표적 탐지가 최적이다. 그러나 IR 이미지는 광학 이미지보다 저화질이고, 텍스처 정보 부족으로 추출 가능한 특징이 적기 때문에 전투체계 운용자가 표적을 정확히 인식하는 데 어려움이 있다. 이러한 문제 해결을 위해 본 연구에서는 EOTS의 IR 운용 환경에 최적화된 딥러닝 모델 기반 자동 표적 인식 시스템을 제안한다. 먼저, 모델의 일반화 성능 확보를 위한 전이 학습을 수행하였으며, IR 이미지에 대하여 전장 상황에서 발생할 수 있는 요소를 반영한 데이터 증강 기법을 적용하였다. 또한, 표적 인식률 향상을 위해 모델 앙상블 기법을 활용하여 함정 전투체계에 적합한 인공지능 모델을 설계하였다. 정량적 분석 결과, 제안 방법은 다양한 대공 및 대함 표적에 대해 정확도 92%의 우수한 인식 성능을 보였다. 따라서 제안하는 시스템은 지능형 함정 전투체계 요소 기술로 활용될 것으로 기대된다.

▶ **주제어:** 지능형 함정전투체계, 전자광학추적장비, 적외선, 자동 표적 인식, 딥러닝, 모델 앙상블

- First Author: Gyu-Seok Do, Corresponding Author: Ji-Seok Yoon
- *Gyu-Seok Do (sp.do@hanwha.com), Naval R&D Center, Hanwha Systems
- *Ju-Mi Park (jumipark1126@hanwha.com), Naval R&D Center, Hanwha Systems
- *Won-Seok Jang (cws0714@hanwha.com), Naval R&D Center, Hanwha Systems
- *Young-Sub Yang (ys77.yang@hanwha.com), Naval R&D Center, Hanwha Systems
- *Ji-Seok Yoon (jsyoon2118@hanwha.com), Naval R&D Center, Hanwha Systems
- Received: 2024. 11. 26, Revised: 2024. 12. 23, Accepted: 2024. 12. 26.



Fig. 1. The Procedure of Naval Combat Management System IR Image-based Target Detection

I. Introduction

함정용 전투체계에서 전자광학추적장비(EOTS; Electro-Optical Targeting System)는 EO(Electro-Optics)/IR(InfraRed) 이미지를 활용해 운용자가 표적을 탐지 및 추적할 수 있는 중요한 장비로써, 교전이 가능하도록 표적 정보를 전투체계로 제공하는 중요한 역할을 하고 있다[1]. 기존 함정 전투체계에서 EOTS를 활용한 표적 탐지 절차는 EOTS로 탐지한 표적의 IR 이미지를 전투체계 장비를 통해 운용자가 운용하는 다기능콘솔에서 확인할 수 있다 (Fig. 1). 이때 표적식별을 위해서는 숙련된 운용자의 경험이 요구된다. 그러나 복잡한 전장 상황에서 신속 정확한 판단을 유지하기 위해서는 학습 기반의 인공지능 기술이 필요하다.

EOTS의 IR 이미지는 객체에서 방출되는 열을 감지하여 이미지를 생성하므로, 야간과 같은 광량이 부족한 환경에서도 효과적으로 사용할 수 있는 장점으로 인해 군사적 목적으로 활발하게 사용되고 있다.

그러나 IR 이미지는 EO 이미지에 비해 낮은 화질과 텍스처 정보의 부족으로 특징점을 추출하는 데 어려움이 있다. 이러한 문제는 전투체계 운용자의 표적 감시 임무를 어렵게 만든다. 이러한 문제를 해결하기 위해 지능형 전투체계를 위한 요소 기술 연구에 관심이 높아지고 있으며, 본 연구에서는 표적 감시 임무의 어려움을 해소하기 위한

지능형 전투체계 핵심 요소 기술인 이미지 인식 기반의 자동 표적 인식(ATR; Automatic Target Recognition) 시스템을 제안한다.

최근 이미지 인식 분야에서 도메인 지식이 필수적인 수치해석 기반의 분류 방법 대신[2, 3], 학습을 통해 모델이 이미지 간 패턴의 차이를 인식할 수 있는 딥러닝(DL; Deep Learning) 기법을 적용한 연구들이 우수한 성능을 나타내고 있다 [4,5]. 하지만, 이러한 우수한 성능을 나타내기 위해서는 충분한 학습 데이터 확보가 필수적이나, 방산 분야에서는 관련 데이터셋을 확보하기가 매우 어렵다. 따라서, 이러한 한계점을 극복하기 위해 제안하는 시스템은 전이학습과 IR 이미지에 최적화된 데이터 증강 기법을 이용하는 방법을 활용해 소규모 데이터셋에 강인한 학습 구조 설계가 필요하다. 또한, 제한된 하드웨어 환경에서 최적의 성능을 나타내는 방안에 대해 검토하고, 앙상블 구조를 활용해 딥러닝 모델의 추론 성능 평가가 필요하다.

본 논문의 2장부터는 제안하는 방법으로, 전이학습, 데이터 증강, 모델 앙상블 방안에 대해 설명하고, 3장은 정량적인 수치를 기반으로 실험 결과를 비교하고 분석한다. 4장에서는 본 연구의 결론을 제시하고 향후 연구 방향을 논의한다.

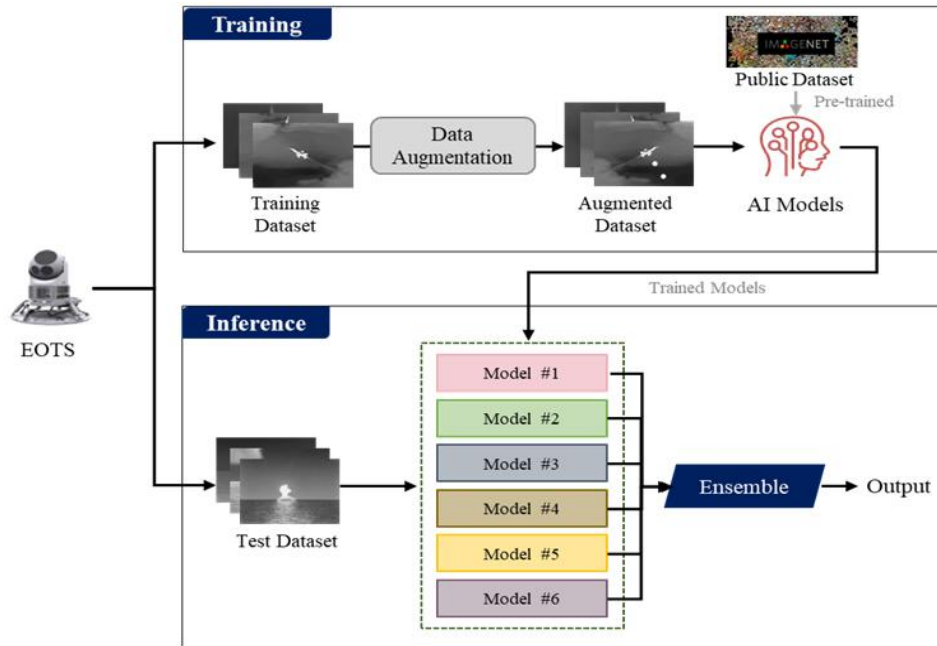


Fig. 2. Proposed ATR System

II. Proposed Methods

제안하는 시스템의 모델 학습 부분은 IR 이미지를 기반으로 데이터 증강을 진행하고, 우수한 성능을 가진 6가지 전이학습 모델을 활용한다. 추론 부분에서는 6가지 모델의 기반으로 여러 가지 앙상블 방식을 적용하여 최적의 시스템을 구성한다(Fig. 2).

1. Training Process

1.1 Transfer Learning

이미지를 분류하는 딥러닝 모델을 활용하기 위해서는 대량의 학습 데이터가 필요하다. 하지만, 국방 분야 특성상 많은 데이터를 확보하여 학습하기 매우 제한적이다. 따라서, 제안하는 시스템은 전이학습 방식을 활용하였다. 더욱이, 대규모 데이터 셋을 통해 다양한 종류의 클래스에 대한 차별점이 사전 학습되어 있기 때문에, 과적합을 줄이고, 모델의 일반화 성능을 향상시킬 수 있다는 장점이 있다.

따라서 제안하는 시스템은 총 6종의 모델로 전통적인 CNN 기반 모델로 ResNet[6]과 VGG[7] 모델을 선정하였고, 최신의 CNN 기반 모델로는 ResNeXt[8]와 ConvNeXt[9]를 선정하였다. 추가적으로 Transformer 기반 모델로 Vision Transformer[10], Swin Transformer[11] 모델을 선정하였다. 전처리 단계에서는 입력 이미지를 전이학습에 적합한 형태로 변환하여, IR 이미지 특성에 최적화된 모델을 학습시킬 수 있도록 했다. ImageNet[12]을 활용하여 학습한 모델의 경우 1,000개

라벨이 출력되며, 본 시스템에 맞춰 6개 라벨에 맞는 Linear layer(1,000, 6)를 추가하여 미세조정 하였다. 이를 통해 1,000개의 라벨을 구분할 수 있는 학습된 가중치를 활용하여 6개의 라벨도 효율적으로 인식할 수 있게 함으로써 높은 인식 성능을 기대할 수 있다.

1.2 Data Augmentation

부족한 IR 이미지 데이터로는 우수한 모델의 성능을 기대하기 어려우므로, 데이터 증강(Data Augmentation)을 통해 IR 이미지 데이터셋의 다양성을 강화하고 모델의 성능을 높이고자 하였다. 실제 EOTS 운용 환경에서 발생할 수 있는 다양한 표적의 영상을 모의하기 위한 데이터 증강 방법들을 선택하였다(Table 1).

Table 1. Data Augmentation

Type	Function
Geometric	Random Resized Crop
	Random Horizontal-Flip
	Random Vertical-Flip
	Random Rotation
	Random Affine
	Random Perspective
Intensity	Random Brightness
	Random Contrast
	Random Equalize
	Random Gaussian Noise

먼저, 표적의 형태 및 위치가 변하더라도 일관된 성능을 유지하기 위해 Geometric 특성을 변화시키는 컴퓨터 비전 알고리즘을 적용하였다. 이는 표적의 다양한 각도로부터 획득되는 이미지를 모사할 수 있다는 장점이 있다. 또한, IR 이미지의 열 신호에 대한 다양한 특성을 부여하기 위해, 픽셀값의 Intensity를 조정하는 방법을 활용하였다.

이와 같이, 실제 전장 상황에서 발생할 수 있는 다양한 시각적 조건 변화에 대하여 강건한 성능의 모델을 학습할 수 있도록 Data Augmentation 함수를 구성하였으며, Data Augmentation의 각 기능은 50%의 확률로 동작하도록 설정하였다. 이를 통해, 각 Epoch 마다 다양한 조건으로 학습될 수 있도록 구성하여 모델의 성능을 향상시켰다.

2. Ensemble

앙상블 기법[12]은 단일 입력에 대한 다양한 출력 결과를 융합하여 모델의 한계를 극복할 수 있는 접근 방법이다. 또한, 함정이라는 제한된 환경 내에서 운용되는 함정 전투체계 시스템의 하드웨어 특성상 부피가 큰 고성능의 하드웨어를 활용하기 어렵고, 국방 분야 특성상 고신뢰 시스템이 요구되기 때문에 앙상블 기법이 최적의 선택이다.

제안하는 시스템에서 3가지 기법을 활용하였으며, 그 중 Geometric[15] 기법은 제한된 하드웨어 환경에서 성능을 높일 수 있고, Averaging[16] 및 Voting[17] 기법은 특성 성능 이상의 하드웨어 사양에서 가장 우수한 성능을 보인다.

2.1 Geometric

Geometric 앙상블 기법은 Test-Time Augmentation (TTA) 형태로 구현되며, 하나의 입력 이미지로부터 여러 개의 변형 데이터를 생성한 뒤 각각의 예측 결과를 결합해 최종 출력을 도출한다. 제안하는 Geometric 앙상블 기법은 이미지 분류 모델에서 원본 이미지를 좌우 반전(Flip),

0도, 90도, 180, 270도 회전(Rotation)한 총 8개 이미지에 대한 예측 결과의 스코어 값을 평균내어 출력하는 방식으로 동작한다.

이러한 방법은 한 개의 모델만이 동작할 수 있는 극단적으로 제한된 환경에서 모델의 추론 성능을 향상시키기 위한 최적의 방법이기 때문에, 본 연구에서 검토하였다.

2.2 Averaging

Averaging 앙상블 기법은 학습된 여러 모델의 예측 결과를 단순히 평균하여 최종 예측값을 산출하는 방법이다. 이 방법은 주로 다중 모델 앙상블 또는 단일 모델의 다중 추론을 통해 구현될 수 있으며, 본 연구에서는 다중 모델 앙상블 방법을 선택하였다. 특히, Averaging 방법은 입력 데이터에 내재된 불확실성을 감소시키고 모델의 예측 편향을 보완하는 데 기여하기 때문에, 안정적이고 신뢰도 높은 추론 결과를 제공한다. 다양한 Edge-Device가 존재하는 함정 전투체계 환경에서 Averaging 기반의 앙상블 방식을 사용하여 추론 성능을 고도화할 수 있기에 연구를 진행하였다.

2.3 Voting

Voting 앙상블 기법 중 본 연구에서는 Hard Voting 방법을 고려하였다. 이 방법은 모델이 예측한 값 중에서 가장 많이 선택된 값을 최종 예측값으로 산출한다. Voting 방식은 예측 결과를 다수결로 결합함으로써, 다중 추론을 병렬 처리하는 속도가 빨라 신속 정확한 의사 결정이 필요한 함정 전투체계에 적합하다. 더욱이 Voting 방식은 Averaging과 유사하게 Edge-Device가 존재하는 함정 전투체계에서 활용하기에 Voting 기반의 앙상블 방법을 고려한 시스템을 검토하였다.




Fig. 3. Synthetic IR Imagery using Diffusion Model-based Generative AI

III. Results and Discussion

1. Dataset

제안하는 시스템을 검증하기 위해서는 가상 데이터를 활용하였다. 가상 데이터 생성 방법에는 다양한 방법들이 있지만, 본 연구에서는 Diffusion 모델[18]을 활용하여 실제와 유사한 IR 이미지를 생성하였다. Diffusion 모델은 무작위 노이즈에서 시작해 점진적으로 정교한 이미지를 생성하는 기술로써, 실제와 유사한 고품질의 이미지를 생성할 수 있다(Fig. 3).

여러 표적 객체 중에서 대공 표적으로 F-16, MiG-19, MiG-21 전투기와 LYNX 헬기를 선정하였고, 대함 표적으로는 PKG, PTG 고속정을 선정하여 이미지를 생성하였다.

제안하는 시스템은 함정전투체계에 적용될 것이므로, EOTS가 포착하는 객체의 이미지는 화염이 뒤덮힌 상황에서도 성능을 보장해야 한다. 따라서 화염이 포함된 표적들도 생성하여 데이터 셋으로 활용하였다. 화염 유무에 따라 50:50의 비율로 각 표적에 대한 이미지를 총 400장씩 생성하였으며, 인공지능 학습을 위해 170장, 검증을 위해 30장, 평가를 위해 200장으로 데이터 셋을 분할하였다(Table 2).

Table 2. List of Experimental Dataset

Class	Training+ Validation	Test	Total
F-16	200	200	400
LYNX	200	200	400
MiG-19	200	200	400
MiG-21	200	200	400
PKG	200	200	400
PTG	200	200	400

2. Experimental Environment

제안하는 시스템은 Pytorch 3.9.6 with CUDA toolkit 12.4, Window10, Nvidia Geforce RTX 4090, AMD 라이젠9 7950x 16코어 CPU, 64GB RAM으로 구성하였다. 데이터 증강 알고리즘은 Pytorch 환경에 최적화된 영상 데이터 증강 모듈인 Kornia[19]를 활용하였다.

각 인공지능 모델 학습을 위해, 입력 이미지를 224x224로 리사이즈하고, 배치 사이즈를 128 개로 설정하였다. 또한, AdamW 최적화 알고리즘을 1e-4의 학습률로 설정하여 총 300번의 학습 과정을 반복하였다(Table 3). 또한, 총 300번의 학습 반복 중, 225번째 Epoch부터 학습된 모델의 가중치를 검증용 데이터 셋에 대해 성능을 평가하여,

가장 뛰어난 성능을 나타낸 가중치를 테스트를 위해 활용하였다.

Table 3. Hyper-parameters

Input size	Batch Size	Optimizer	Epoch	Learning Rate
224x224x3	128	AdamW [13]	300	1e-4

3. Experimental Results

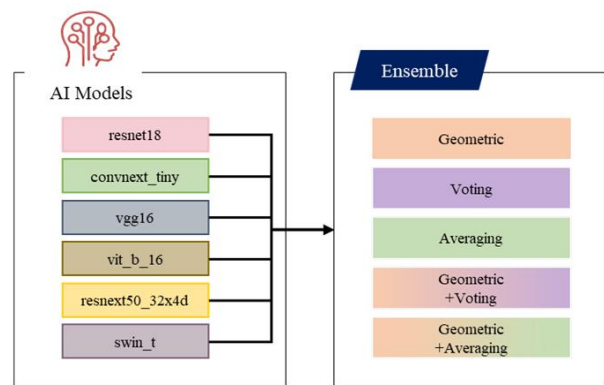


Fig. 4. Details of AI Models and Ensemble Methods in the Inference Process

제안된 시스템을 위해 앞서 2.1절에서 언급한 6가지 모델을 선정하였다. 각 모델의 사전 학습된 가중치는 ResNet18, ConvNext_tiny, VGG16, VIT_b_16, ResNeXt50_32x4d, Swin_T 이며, Pytorch Hub를 통해 구현되었다. 이를 활용하여, 학습 데이터 증강 기법 유무에 따른 위 6종 인공지능 모델에 대한 성능 평가를 수행하였다.

또한, 6종 인공지능 모델을 기반으로, 총 5종의 앙상블 기법을 적용하여 성능 평가를 수행하고, 성능을 비교하였다. 여기서, 5종의 앙상블 기법은 Geometric, Voting, Averaging 각각과 Geometric과 Voting 조합, Geometric과 Averaging 조합으로 구성하여 실험하였다(Fig. 4.).

자동 표적 인식 모델의 정량적 성능 평가를 위해, 수신자 조작 특성(ROC) 특성[20]을 활용하여 정확도(Acc.), 특이도(Spec.), 정밀도(Prec.), 재현율(Rec.) 및 F1점수(F1.)를 분석하였다.

Table 4. Comparison Result Using Various Types of DL Model

Data Augmentation	Metric	Model					
		VGG	ResNet	ResNeXt	Vision Trans.	ConvNeXt	Swin Trans.
×	Acc.	0.7950	0.7050	0.7792	0.7733	0.8525	0.8050
	Spec.	0.9590	0.0941	0.9558	0.9547	0.9705	0.9610
	Prec.	0.8019	0.7084	0.7830	0.7845	0.8513	0.8110
	Rec.	0.7950	0.7050	0.7792	0.7733	0.8525	0.8050
	F1.	0.7976	0.7060	0.7798	0.7766	0.8515	0.8056
○	Acc.	0.8642	0.8542	0.8892	0.8833	0.9025	0.8833
	Spec.	0.9728	0.9708	0.9778	0.9767	0.9805	0.9767
	Prec.	0.8708	0.8593	0.8922	0.8843	0.9063	0.8841
	Rec.	0.8642	0.8542	0.8892	0.8833	0.9025	0.8833
	F1.	0.8648	0.8558	0.8892	0.8837	0.9032	0.8833

Table 5. Confusion Matrix Result of Geometric Ensemble ConvNeXt Model

True \ Pred.	Pred.					
	F-16	LYNX	MiG-19	MiG-21	PKG	PTG
F-16	181	0	4	15	0	0
LYNX	3	194	1	2	0	0
MiG-19	15	1	166	18	0	0
MiG-21	26	2	7	165	0	0
PKG	0	0	0	0	191	9
PTG	0	0	0	0	9	191
Acc.	0.9475	0.9925	0.9617	0.9417	0.9850	0.9850
Spec.	0.9560	0.9970	0.9880	0.9650	0.9910	0.9910
Prec.	0.8044	0.9848	0.9326	0.8250	0.9550	0.9550
Rec.	0.9050	0.9700	0.8300	0.8250	0.9550	0.9550
F1.	0.8518	0.9773	0.8783	0.8250	0.9550	0.9550

Table 6. Comparison Result Using Various Types of Ensemble Model

Metric	Ensemble				
	Geometric (ConvNeXt)	Voting	Averaging	Geometric +Voting	Geometric +Averaging
Acc.	0.9067	0.9125	0.9200	0.9075	0.9192
Spec.	0.9813	0.9825	0.9840	0.9815	0.9838
Prec.	0.9095	0.9135	0.9211	0.9097	0.9208
Rec.	0.9067	0.9125	0.9200	0.9075	0.9192
F1.	0.9071	0.9125	0.9201	0.9078	0.9194

Table 4. 평가 결과에 따르면 실험에 활용된 6가지 모델 중 ConvNeXt 모델이 다른 모델에 비해 정확도가 가장 높았다. 또한 6가지 모델 모두 데이터 증강 방식이 적용된 결과가 우수하다는 것을 알 수 있었다. 가장 높은 개선을 보인 모델은 ResNet 모델로, 데이터 증강을 적용하고 난 뒤 17.47%로 가장 높은 개선을 보여줬다. 가장 낮은 개선을 보인 모델은 ConvNext_tiny 모델로, 5.54%로 가장 낮은 개선을 보였다.

데이터 증강을 적용하지 않은 상태에서 학습된 각 모델의 정확도는 ConvNeXt, Swin Transformer, VGG,

ResNeXt, Vision Transformer, ResNet 순으로 높았다.

데이터 증강이 적용된 상태에서는 ConvNeXt, ResNeXt, Vision Transformer, Swin Transformer, VGG, ResNet 순으로 최신 CNN 모델이 전통적인 CNN 기반 모델보다 성능이 우수하였으며, 최신 CNN 기반 모델, Transformer 모델, 전통적인 기반 CNN 모델 순으로 성능이 좋음을 확인할 수 있었다.

앞서 학습한 모델의 추론 성능을 높이기 위해 앙상블 기법을 적용해 보았다. 대표적으로 실험에서 가장 성능이 좋았던 모델인 ConvNeXt 모델 기반으로 Geometric 앙상블

을 적용해 보았다. 해당 결과는 예측 성능을 라벨별로 확인하기 위해 Confusion Matrix를 작성하였다(Table 5). 6가지 라벨 중 LYNX가 제일 정확도가 높았으며, MiG-19, MiG-21이 가장 낮음을 확인할 수 있었다. 또한, MiG-19, MiG-21 라벨은 종종 F-16 라벨로 인식함을 함께 확인할 수 있었다. 이를 통해 대공 표적 중 헬기를 제외한 전투기 표적 간의 유사도가 가장 높다는 것을 알 수 있다.

양상블 방식을 단독 혹은 혼합하여 여러 가지 양상블 방식으로 실험하였다(Table 6). 단순 Geometric 방식만 적용한 ConvNeXt 모델은 미적용 모델보다 정확도가 0.46% 정도 향상되었다.

가장 뛰어난 성능을 가진 양상블 기법은 0.92의 정확도를 가진 Averaging 방식이었다. 두 가지 양상블 방식을 적용한 결과는 Geometric 방식보다는 좋은 결과를 보여주었지만, Voting과 Averaging 방식만 적용한 결과보다 낮은 성능을 나타내어 제한된 하드웨어 환경 내에서는 계산의 복잡도만으로 성능을 향상시키는 방법은 한계가 있음을 확인하였다.

IV. Conclusions

본 연구에서는 지능형 함정 전투체계를 위한 딥러닝 기반의 IR 이미지의 객체를 자동 인식할 수 있는 ATR 시스템에 대해 제안하였다. 이 시스템에서 설계된 모델은 사전 학습된 6가지 모델을 활용하여 시스템의 성능을 비교해 보았다.

실험 결과를 통해 데이터 증강 방식의 적용은 딥러닝 모델 성능 향상에 도움이 된다는 것을 확인할 수 있었다. 이처럼 소량의 학습 데이터를 활용할 경우 데이터 증강이 모델 성능 향상에 영향을 끼친다고 판단할 수 있었다. 또한 학습 데이터 증강 유무와 관계없이, 최신의 CNN 기반의 모델인 ConvNeXt 모델이 가장 우수한 정확도를 보였다.

Geometric 방식을 사용하면 단일 개별 모델의 성능 향상이 확인되었지만, Voting 방식과 Averaging 방식에 비해 성능이 낮은 것을 확인하였다. 그러므로 Geometric 방식은 함정 전투체계에서 저사양의 하드웨어를 탑재한 장비에서 독립적으로 성능을 향상시킬 수 있다. 반면 고사양의 하드웨어를 탑재한 장비의 경우에는 여러 모델의 추론 값을 바탕으로 Averaging 방식을 적용하는 것이 더 효율적이다. 이를 통해 제안된 시스템은 소량의 IR 데이터만으로도 함정 전투체계에서 대공 표적인 전투기와 헬기, 대함 표적인 함정을 자동 인식하는 지능형 전투체계의 요소 기술로 활용될 수 있음을 검증하였다.

향후 연구에서는 지식증류(Knowledge Distillation)[21] 기법을 적용하여 모델을 경량화시켜 Edge Device와 같은 제한된 환경에서도 우수한 성능을 가진 모델을 적용한 시스템을 구현하고자 한다. 또한 IR 이미지에 최적화된 네트워크를 설계하여 모델의 성능을 확인할 것이며, 실제 데이터를 확보하여 모의 데이터와 비교 실험하며, 실제 환경에서 우수한 성능을 가진 모델을 시스템에 적용할 계획이다.

REFERENCES

- [1] B. Shim, H. Jo, and J. Kim, "A Study on Dependency Tracking Target Aiming Systems Improvement of the Naval Electro Optical Tracking Systems," *Journal of the Institute of Electronics and Information Engineers*, Vol. 52, No. 9, pp. 125-131, Sep. 2015. DOI: 10.5573/ieie.2015.52.9.125
- [2] J. Heo, H. Jeon, Y. Kong, Y. Nam, P. Ley, S. Min, M. Hong, D. Oh, and W. Shin, "A Preliminary Study on Diagnosis of Breast Cancer using a Thermal Camera," *The Korean Institute of Electrical Engineers*, pp. 13-17, Feb. 2016.
- [3] J. Lee and S. Lee, "Application of the Rule-Based Image Classification Method to Jeju Island," *Journal of Korea spatial information society*, Vol. 21, No. 1, pp. 63-73, Feb. 2013. DOI: 10.12672/ksis.2013.21.1.063.
- [4] H. Karus, F. Schwenker, M. Munz, and M. Teutsch, "Towards Explainable Visual Vessel Recognition Using Fine-Grained Classification and Image Retrieval," *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 82-92, 2024.
- [5] H. Zhang, C. Liu, J. Ma, and H. Sun, "Ship Infrared Automatic Target Recognition Based on Bipartite Graph Recommendation: A Model-Matching Method. *Mathematics*," Vol. 12, No. 1, pp.168, 2024. DOI: 10.3390/math12010168
- [6] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770-778, 2016.
- [7] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
- [8] S. Xie, R. Girshick, P. Dollár, Z. Tu, and K. He, "Aggregated residual transformations for deep neural networks," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1492-1500, 2017.
- [9] Z. Liu, H. Mao, Y. Wu, C. Feichtenhofer, T. Darrell, and S. Xie, "A convnet for the 2020s," *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 11976-11986, 2022.

- [10] A. Dosovitskiy, "An image is worth 16x16 words: Transformers for image recognition at scale," arXiv preprint arXiv:2010.11929, 2020.
- [11] Z. Liu, Y. Lin, Y. Cao, H. Hu, Y. Wei, Z. Zhang, S. Lin, and B. Guo, "Swin transformer: Hierarchical vision transformer using shifted windows," Proceedings of the IEEE/CVF international conference on computer vision, pp. 10012-10022, 2021.
- [12] Imagenet, <https://image-net.org/>
- [13] I. Loshchilov, and F. Hutter, "Fixing weight decay regularization in adam," arXiv preprint arXiv:1711.051015, 2017.
- [14] T. Dietterich, "Ensemble methods in machine learning," International workshop on multiple classifier systems, Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 1-15, Jun. 2000.
- [15] L. Kuncheva, "Combining pattern classifiers: methods and algorithms," John Wiley & Sons, 2014.
- [16] L. Hansen and P. Salamon, "Neural network ensembles," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 12, No. 10, pp. 993-1001, 1990.
- [17] Lam, Louisa, and S. Y. Suen. "Application of majority voting to pattern recognition: an analysis of its behavior and performance," IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans, Vol. 27, No. 5, pp. 553-568, 1997.
- [18] R. Rombach, A. Blattmann, D. Lorenz, P. Esser, and B. Ommer, "High-resolution image synthesis with latent diffusion models," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 10684-10695, 2022.
- [19] E. Riba, D. Mishkin, D. Ponsa, E. Rublee, and G. Bradski, "Kornia: an open source differentiable computer vision library for pytorch," Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, pp. 3674-3683, 2020.
- [20] M. Grandini, E. Bagli, and G. Visani, "Metrics for multi-class classification: an overview," arXiv preprint arXiv:2008.05756, 2020.
- [21] J. Gou, B. Yu, S. Maybank, and D. Tao, "Knowledge distillation: A survey," International Journal of Computer Vision, Vol. 129, No. 6, pp. 1789-1819, 2021.

Authors



Gyu-Seok Do received the B.S degrees in Electronic Engineering from Kyungpook National University, South Korea. He is currently working in Hanwha Systems Co. from 2016. He is interested in Intelligent

Naval Combat Management System using Artificial Intelligence and System Engineering.



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, Korea. She is currently working in Hanwha Systems Co. from 2023. She is interested in Intelligent Naval Combat System using Artificial Intelligence.



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.



Young-Sub Yang received the B.S degrees in Electronic Communication Engineering from Kumoh National Institute of Technology, South Korea. He is currently working in Hanwha System Co. from 2002.

He is interested in Intelligent Naval Combat Management System, Multi-Function Radar System and Integrated Sensor Mast.



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 (GIST), Gwangju, South Korea, in 2014 and 2021. From 2021 to 2023, he 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.