Journal of the Korea Academia-Industrial cooperation Society
Vol. 24, No. 7 pp. 189-196, 2023

https://doi.org/10.5762/KAIS.2023.24.7.189
ISSN 1975-4701 / eISSN 2288-4688

Sim2Real 학습을 활용한 무기체계 탐지성능 향상에 대한 연구

이경재, 마정목*
국방대학교 무기체계학과

A Study on Improving Weapon System Detection Performance Using Sim2Real Learning

Gyeong-Jae Lee, Jung-Mok Ma*
Division of Weapon System, Korea National Defense University

요 약 딥러닝 기반의 객체탐지 모델에서 새로운 객체에 대한 탐지를 위해서는 해당 객체가 포함된 방대한 이미지를 모델에 학습시켜야 한다. 하지만 충분한 이미지 데이터를 확보하기 힘든 환경에서는 모델을 학습시키기에 불리한 면이 있으며 국방 분야가 대표적인 예이다. 이와 같은 문제를 해결하기 위해 데이터 생성에 해당되는 시뮬레이션 가상환경에서의 3D 모델 기반의 합성이미지를 이용하여 컴퓨터가 학습할 수 있는 충분한 양의 데이터풀을 확보하고 객체탐지 모델을 학습시킬 수 있다. 이를 Sim2Real 학습이라고 하며, Sim2Real의 성능을 보장하기 위해서는 도메인 격차를 줄이는 과정이 필요하다. 본 연구에서는 도메인 격차를 줄이는 도메인 적응화 기법 중 하나인, 가상의 도메인에서 수집한 학습데이터로 학습한 객체탐지 모델의 가중치를 가지고 실제 도메인에서 수집한 이미지로 재학습하는, 미세조정 과정을 수행했을 때 성능 차이를 비교하여 도메인 적응화 기법이 실제로 탐지성능에 유의미한 영향을 미치는지 분석하고자 하였다. 실험 결과 적은 양의 실제이미지를 가지고 미세조정을 통해서 유의미한 성능 향상이 있음을 보았다. 이는 충분한 양과 질을 가진 학습용 이미지를 구하기 힘든 국방 분야에서, 객체탐지 모델을 학습하는 한 방향성을 제시해줄 수 있다.

Abstract The detection of a new object in a deep learning-based object detection model requires the model to be trained with many images containing the objects. On the other hand, in an environment where it is difficult to obtain sufficient image data, there is a disadvantage in training a model, and the defense field is the representative example. The 3D model-based synthetic image in the simulated virtual environment corresponds to data generation to solve this problem by preparing a sufficient data pool for the computer to learn the object detection model. This is called Sim2Real learning, and a process of reducing the domain gap is required to guarantee the performance of Sim2Real learning. This study performed a fine-tuning process of re-learning with images collected from a real domain with weights of object detection model learned with synthetic images collected from the virtual domain, which is one of the domain adaptation techniques to reduce domain gap. This study analyzed whether the domain adaptation technique effectively detects performance by comparing the differences in results. As a result of the experiment, there was significant performance improvement through fine-tuning with a small number of real images. This can suggest a direction for learning object detection models in the field of national defense, where it is not easy to obtain training images of sufficient quantity and quality.

Keywords : Deep Learning, Object Detection, Data Generation, Synthetic Image, Sim2Real, Fine-tuning

*Corresponding Author : Jung-Mok Ma(Korea National Defense Univ.)
email: jxm1023@gmail.com
Received May 15, 2023 Revised June 12, 2023
Accepted July 7, 2023 Published July 31, 2023

1. 서론

딥러닝 기반의 객체탐지 모델은 주어진 이미지 데이터를 인공신경망 기법을 통해 데이터의 특징을 학습하는데, 충분한 성능을 위해서는 많은 데이터가 필요하다. 동시에 다양한 상황에서의 성능을 보장하기 위해서는 충분하면서도 유의미한 데이터를 확보해야 하는데, 이는 고난도이면서 고비용 업무이다보니 딥러닝 분야에 있어서 매번 큰 도전과제로 여겨진다. 특히, 보안을 중요시하는 국방 분야 특성상, 객체탐지 모델이 학습해야 하는 특정 무기체계에 대한 충분한 데이터셋을 구축하는 것은 더욱 어려울 수밖에 없다. 더해서, 피·아가 혼재된 전장 속에서 형태가 유사한 무기체계를 구분할 수 있을 만큼의 고성능을 보장하기 위해서는 더 다양하고, 더 정교하며, 더 유의미한, 양질의 데이터가 필요하다. 이러한 데이터 문제를 해결하기 위해 데이터 생성(data generation)과 데이터 증강(data augmentation) 등 다양한 연구가 이루어지고 있으며 본 연구에서는 데이터 생성에 해당하는 방법 중 하나인 3D 모델 기반의 합성이미지 생성을 통해 학습데이터셋을 구성한다.

Sim2Real(simulation to real world) 학습은 가상의 시뮬레이션 환경에서 학습데이터를 생성하여 딥러닝 모델을 학습시킨 이후 실제 환경에 적용하는 방법으로, 최근 컴퓨터비전 분야에서 각광받는 분야이다. 그 이유는 렌더링된 3D 모델만 주어진다면 다양한 각도에서 객체의 모습을 촬영할 수 있고, 객체의 색이나 질감을 자유롭게 변형시킬 수 있으며, 3D 모델이 구현되어있는 주변 환경을 변화시킴으로써 학습데이터의 다양성을 확보할 수 있어, 객체의 한 면만을 학습하는 등의 편향을 줄이는데 중요한 역할을 할 수 있기 때문이다. 하지만 이러한 합성 이미지는 실제 이미지와 비교했을 때 미세한 질감 차이와 현실 세계의 복잡성을 반영하지 못하기 때문에 도메인 격차(domain gap)가 발생하게 된다. 여기서 도메인이란 데이터가 생성되거나 수집된 환경을 가리키는 용어로, 합성이미지는 가상의 도메인(virtual domain)에서 생성 및 수집되며 실제이미지는 현실의 도메인(real domain)에서 생성 및 수집된다.

본 연구에서는 전차를 대상으로 한 객체탐지 모델의 성능을 향상시키기 위해 Sim2Real 학습의 단점인 도메인 격차를 줄이기 위한, 도메인 적응화(domain adaptation) 기법 중 하나인 미세조정(fine-tuning)을 적용하였을 때 모델의 탐지성능이 어떻게 변화되는지를 확인함으로써 그 효용성을 분석하고자 한다.

Fig. 1. 3D models of tank shape[1]

이를 위해, Fig. 1에서와 같이 오픈소스 군사 시뮬레이션 게임인 'DCS(Digital Combat Simulation) World' [1]에 탑재되어 있는 3D 모델 중 5개 주요국의 대표적인 전차 3D 모델을 이용하여 대량의 학습용 합성이미지를 생성하고, 객체탐지 모델을 학습시킨다. 이후 합성이미지로 사전학습된 모델의 가중치를 이용하여 소량의 실제 이미지를 다시 학습하는 미세조정 과정을 진행한다. 마지막으로 합성이미지만으로 학습한 모델과 미세조정 과정을 거친 모델로 각각 실제이미지를 대상으로 탐지실험을 진행함으로써 성능의 차이를 확인하고자 한다. 본 연구의 2장에서는 연구에 사용된 객체탐지 모델 및 합성데이터를 이용한 딥러닝 학습에 대한 관련 연구를 알아본다. 3장은 실험 데이터셋의 구성과 미세조정 여부에 따른 성능을 평가하고 4장은 연구의 결론을 도출한다.

2. 관련 연구

2.1 객체 탐지

딥러닝 기반의 컴퓨터비전 분야에는 분류(classification), 객체탐지(object detection), 개체 분할(instance segmentation)이 있다. 분류는 이미지 상에서 객체의 종류를 분류하는 분야이며 객체탐지는 이미지 내에 있는 객체의 위치와 종류를 식별한다. 개체 분할 분야는 객체탐지와 유사하지만 객체를 픽셀 단위로 검출하기 때문에 더 많은 비용과 시간이 드는 분야라고 할 수 있다.

객체탐지를 위한 딥러닝 모델은 2002년 이후 지속적으로 발전하고 있으며[2] 크게 1단계 검출기(one-stage detector)와 2단계 검출기(two-stage detector)로 구분할 수 있다. 대표적인 1단계 검출기 모델은 YOLO(You Only Look Once) 또는 SSD(Single Shot Detector)가 있으며[3,4] 2단계 검출기 모델은 R-CNN(Regions with Convolutional Neural Network) 계열이 있다[5]. 1단

계 검출기는 하나의 CNN에서 객체를 검출하고 분류하는 과정이 동시에 처리되고 2단계 검출기는 객체를 검출하는 과정과 분류하는 과정이 순차적으로 이루어진다.

본 연구에서 사용하는 YOLO 모델은 Fig. 2에서와 같이 이미지를 수 개의 그리드로 나눈 후에 각 그리드별 객체가 포함된 바운딩 박스(bounding box)와 신뢰도(confidence score)를 계산함으로써 최종적으로 이미지 내 객체의 위치와 종류를 특정하는 모델이다. 일반적으로 2단계 검출기 모델에 비해 정확도는 낮지만 예측 속도가 빨라 실시간 객체탐지에 주로 사용되어 왔으며 그 중, 본 연구에서 사용하는 YOLOv5 모델은 기존의 모델에 비해 성능이 향상되고, 가중치의 용량을 낮추어 연산 속도가 더 빠르다는 장점이 있으며 이전 버전과 다르게 Pytorch 기반으로 구성되었다.

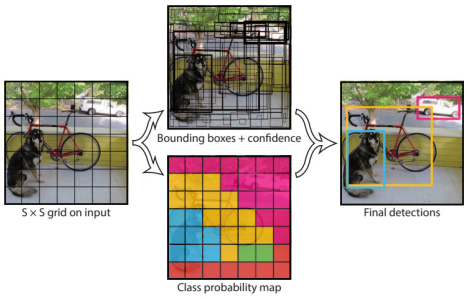

Fig. 2. Detection process of YOLO model[3]

2.2 합성데이터 딥러닝 학습

합성데이터 중에서도 컴퓨터비전 분야에서 사용되는 합성이미지(synthetic image)는 어떤 사물에 대한 실제 이미지가 아닌, 시뮬레이션 또는 그래픽디자인 프로그램을 이용하여 생성한 가상의 이미지를 말한다. 최근, 컴퓨터비전 분야에서 모델이 학습하기에 충분한 양의 실제 이미지를 수집하기 힘든 경우에 유망한 접근법으로써 다양한 연구가 진행되고 있다.

합성데이터 생성기술은 크게 데이터 증강(data augmentation), 생성 모델(generative model), 시뮬레이션(simulation)으로 분류할 수 있다[6]. 데이터 증강은 가장 기본적인 활용방법의 하나로, 원본 데이터에 노이즈 삽입, 색상 및 질감 변경, 자르기, 가르기 등의 변형을 가한 데이터를 학습데이터로 추가 활용함으로써 학습데이터의 다양성을 보강하는 방법이다. 생성모델은 AI 알고리즘으로 합성데이터를 생성한다. 기존에 주어진 소량의 학습데이터의 통계적 특성과 확률 분포를 학습하여 이와 유사한 특성을 갖는 가상의 데이터를 생성한다. 딥페이크 데이터 합성기술로 널리 알려진 GAN(Generative Adversarial Network)과 VAE(Variational AutoEncoder)가 대표적인 모델이다. 시뮬레이션 데이터는 Unity, Unreal 등과 같은 게임엔진을 활용하여 실제와 비슷한 형상의 데이터를 확보하거나, CAD 등을 이용해 실제와 유사한 데이터를 생성하는 방법이다[7].

현대 렌더링 기술의 발전으로, 3D 모델만 주어진다면 신속하면서도 저비용으로 수천 장의 이미지를 생성하는 것이 가능할 뿐만 아니라 카메라의 구도, 모델의 형질 변형, 주변 환경의 변화 등을 통해 학습데이터의 다양성과 품질을 향상시킬 수 있다. 하지만 단점으로는, 육안상으로 실제같이 보인다 하더라도 여전히 합성이미지와 실제 이미지 사이에 미세한 차이는 존재하며, 이는 합성이미지로 학습한 모델로 하여금 실제이미지를 탐지할 때 성능을 충족하지 못하게 만들 수 있다. 이런 현상을 도메인 격차라고 한다[8].

도메인 격차를 줄이기 위한 연구도 다수 진행되어 왔으며 대표적인 방법으로는 도메인 적응화(domain adaptation)와 도메인 무작위화(domain randomization)가 있다. 도메인 적응화는 가상의 이미지를 현실의 배경이미지에 합성하여 학습데이터셋을 구축하는 등, 학습데이터가 실제 환경의 분포와 맞출 수 있도록 하는 작업이며 도메인 무작위화는 3D 모델 객체의 색, 질감, 객체가 포함된 배경, 객체에 비친 빛, 객체 주변의 먼지, 안개 등 주변 환경을 변경하는 등의 방법을 통해 객체탐지 모델이 다양한 환경에 적응할 수 있게 하는 작업이다. 예시로 Eversberg[9]은 Sim2Real 학습 방법을 이용하여 산업현장에서의 터빈 날개를 탐지하는 모델을 학습시키기 위해 Fig. 3에서와 같이 도메인 적응화와 도메인 무작위화를 모두 적용한 바 있다.

Fig. 3. Examples of domain adaptation and randomization(revised from [9])

본 연구에서는 학습 데이터의 다양성과 품질을 높이기 위해 군사 시뮬레이션 게임 DCS World의 자체 게임 엔진인 EDGE 엔진에 구축되어있는 전차 3D 모델을 이용하여 객체의 색상, 질감 변형과 주변환경의 변화, 시뮬레이션 조작을 통해 교전 및 도하 상황을 묘사함으로써 도메인 무작위화를 적용하였다. 이후, 대량의 합성이미지로 사전학습된 모델의 가중치를 소량의 실제 이미지로 미세조정하고 성능을 비교함으로써 도메인 적응화의 효용성을 분석하고자 한다.

2.3 Sim2Real 탐지에서 도메인 적응화 적용

이형근[10]은 군사 환경에서의 데이터 수집 문제를 해결하기 위해 Unity 게임엔진에서 전차가 포함된 가상환경을 구축하고 촬영기능을 통해 객체탐지 모델 학습용 합성이미지를 생성하였다. 이후 합성이미지를 조작함으로써 도메인 적응화를 적용하기 위해 FastPhotoStyle 어플리케이션을 활용하였다. Fig. 4와 같이, 시뮬레이션 엔진으로 생성한 합성이미지 (b)에 어플리케이션을 이용하여 실제이미지 (a)를 적용한 결과로, 실제 사진의 질감을 가진 이미지 (c)로 변환하여 학습데이터를 추가하였다. 합성이미지와 변환이미지를 혼합하여 학습했을 때 모델의 성능이 더 향상됨을 확인함으로써 합성이미지를 이용한 Sim2Real 학습 간에 추가적으로 성능을 개선하는 방법을 제안하였다.

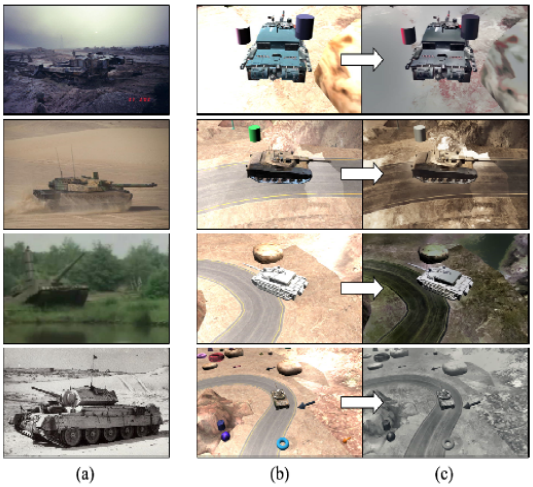

Fig. 4. Photo-realistic transformation of synthetic images[10]

문성원[11]은 데이터 확보가 제한되는 군함을 대상으로 한 탐지모델을 학습시키는 데에 합성데이터의 효용성을 입증하기 위해 Fig. 5와 같이 실사 군함 사진을 기반으로 3D 모델을 제작하였다. 이후, 도메인 적응화 기법인 준지도 Minimax Entropy를 적용한 합성이미지와 그렇지 않은 합성이미지를 생성한 다음 소량의 실제 이미지와 도메인 적응화 기법을 적용한 합성 이미지를 같이 학습시킨 객체탐지 모델이 그렇지 않은 모델보다 더 성능이 향상됨을 확인한 바 있다.

Fig. 5. Real warship(up) and Synthetic warship (down)[11]

3. 객체탐지 실험

3.1 실험 목적

본 실험의 목적은 Sim2Real 학습에서 대량의 합성이미지로 학습한 객체탐지 모델에 소량의 실제이미지로 미세조정하는, 도메인 적응화 과정을 거칠 때, 실제로 성능이 유의미하게 향상되는지 여부를 확인하는 것이다. 실험을 진행하기 위해 Fig. 6에서와 같이, 시뮬레이션 게임 엔진을 이용하여 대량의 3D 모델 기반 합성이미지를 생성하여 학습 데이터셋을 구성하고, 인터넷을 통해 미세조정 및 탐지의 대상이 되는 실제이미지를 수집한다. 모든 이미지에 주석을 붙이는 라벨링 과정을 거친 이후 합성이미지만으로 객체탐지 모델을 학습시키고, 탐지하고자 하는 전차의 실제이미지를 이용하여, 사전학습된 모델의 가중치에 대해 미세조정을 진행한다. 마지막으로 미세조정하는 실제이미지의 양을 증가시켜가면서 모델 성능의 차이를 확인한다.

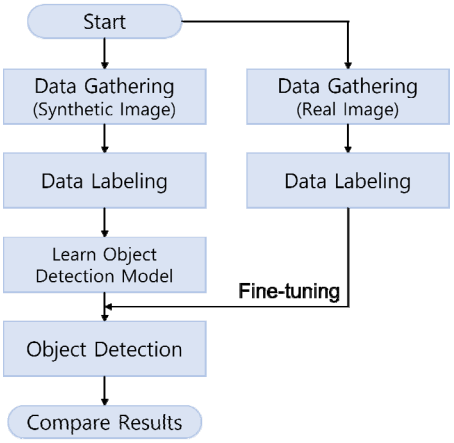

Fig. 6. Research flow chart

3.2 데이터 구성

3.2.1 학습 데이터셋

학습에 사용되는 이미지는 주요국들의 대표적인 전차들이다. DCS World 게임 엔진상에 전차의 모델을 구현하고 모델 중심으로 카메라의 구도를 회전하면서 촬영을 통해 다각도에서의 전차의 모습이 담긴 합성이미지를 생성하였으며 전차의 종류는 다섯 종류로, 미국의 M1A2, 프랑스의 Leclerc, 독일의 Leopard, 이스라엘의 Merkava, 러시아의 T90 전차에 대해 각 종류별 1200장의 학습용 데이터셋을 구성하였다.

Table 1. Dataset used in the study

Name	M1A2	Leclerc	Leopard	Merkava	T90
Training (synthetic)	1200	1200	1200	1200	1200
Fine-tuning (real)	50	50	50	50	50
Test (real)	50	50	50	50	50

또한, 학습데이터의 품질을 높이기 위해 도메인 무작위화를 적용하였다. Fig. 7와 같이 빛의 각도, 비내림, 전차 모델의 질감 등을 변형시킨 합성이미지와, Fig. 8와 같이 기동, 전투, 나무에 의한 가려짐 등 시뮬레이션 기능을 통해 주변 환경을 조작한 합성이미지를 생성하였다. 그리고 실험의 목적인 도메인 적응화를 적용하기 위한 미세조정용 전차 실제이미지를 종류별 50장씩 구성하였다.

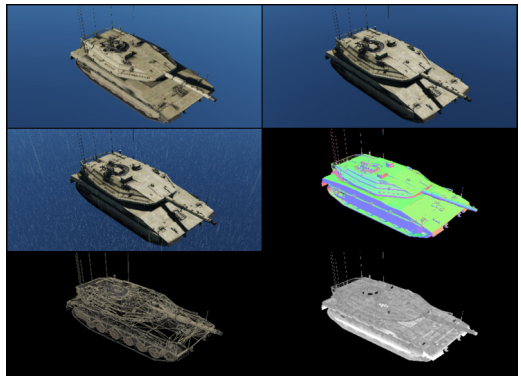

Fig. 7. Domain randomization by manipulating model

Fig. 8. Domain randomization by changing circumstances

3.2.2 탐지대상 데이터셋

탐지 대상이 되는 실제 도메인의 전차 사진은 Google 이미지를 활용하여, 학습 데이터셋의 전차들과 같은 기종으로 종류별 50장으로 데이터셋을 구성하였으며 Fig. 10와 같이 전차의 전·측면과, 기동 및 사격 등 다양한 상황 하에서의 전차 이미지를 포함하였다. 학습용 이미지와 탐지대상 이미지는 모두 960 × 540 pixel 사이즈로 설정하였다.

Fig. 9. Examples of target image dataset

3.3 평가지표

객체탐지 성능을 평가하기 위해서는 혼동행렬(confusion matrix)의 해석과 IoU(Intersection over Uinion)에 대한 이해가 필요하다. 먼저, 혼동행렬은 Table 2와 같이, 객체탐지 모델의 예측 결과(predicted result)와 실제 정답(ground truth)의 교차표로써 TP는 검출한 결과에 객체가 존재한 경우, FN은 검출되지 않은 결과에 객체가 존재한 경우, FP는 검출한 결과게 객체가 존재하지 않은 경우, TN은 검출되지 않은 결과에 객체가 존재하지 않은 경우를 뜻한다.

Table 2. Confusion Matrix

Ground truth	Predicted result	
	Positive	Negative
Positive	TP	FN
Negative	FP	TN

객체탐지 모델의 성능 평가지표인 AP(Average Precision)는 혼동행렬 내의 계산값인 정확도(precision)와 재현율(recall)의 조합을 통해 계산되는데, 정확도는 모델이 정답이라고 검출한 결과등 중에 실제 정답을 검출한 비율이며 재현율은 실제 정답 중에 모델이 정답이라고 검출한 비율을 뜻하고 정확도와 재현율을 구하는 식은 Eq. (1)과 같다.

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

하지만 정확도와 재현율만으로는 객체탐지 모델의 성능을 설명하기 어렵다. 그 이유는 정확도 값이 높은 경우 재현율 값은 낮은 경향이 있고, 반대로 정확도 값이 낮은 경우 재현율 값은 높은 경향이 있기 때문이다. 이러한 문제로 모델의 성능을 표현하기 위해 PR Curve(Precision-Recall Curve)의 아랫면적 넓이에 해당하는 AP를 객체탐지 모델의 성능 평가지표로 사용한다. 본 연구에서는 AP_0.5를 평가지표로 사용하며 AP_0.5는 IoU의 임계값이 0.5일 때의 예측을 TP 값으로 사용한다. IoU는 실제 정답의 바운딩 박스와 모델이 예측한 바운딩 박스가 전체 박스 중에 얼마나 겹치는지 계산한 값으로, 구하는 식은 Eq. (2)와 같다.

$$IoU = \frac{area(Ground\ Truth \cap Prediction)}{area(Ground\ Truth \cup Prediction)} \qquad (2)$$

3.4 실험결과

합성이미지만으로 학습한 객체탐지 모델과 미세조정 과정을 거친 모델을 이용하여 각 250장의 실제이미지를 탐지한 AP_0.5 결과는 Fig. 11와 같다. 파란색 선이 5개 전차 종류별 탐지성능 AP값들의 평균인 mAP(mean Average Precision)이다.

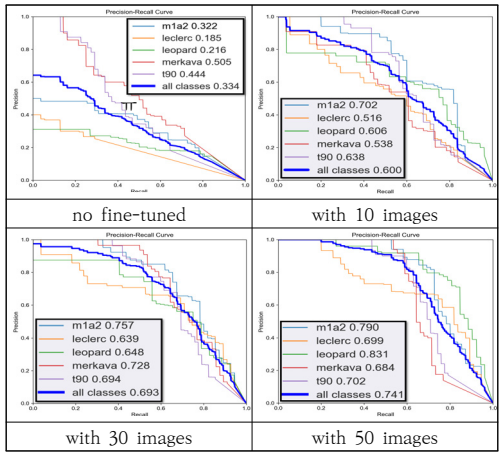

Fig. 10. PR Curves of fine-tuned models

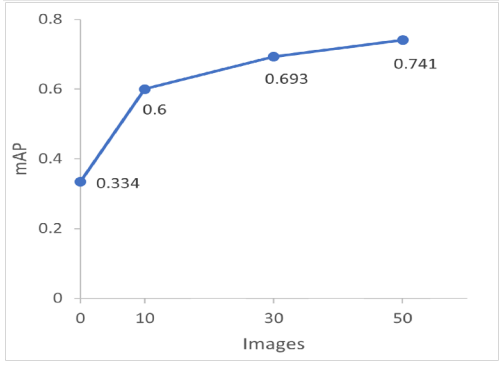

Fig. 11. mAP per images used for fine-tuning

Fig. 11에서와 같이 미세조정에 사용된 실제 이미지의 장수가 늘어남에 따라 성능이 향상되는 것을 확인할 수 있다. 특히, 미세조정을 거치지 않은 모델에 비해 10장의 이미지로 미세조정을 거친 모델의 성능이 가장 높은 차이로 향상된 점을 볼 때, 소량이 이미지만이라도 도메인 적응화를 적용하는 것이 모델의 성능 향상에 유의미한 영향을 줄 수 있다는 것을 알 수 있다. Fig. 12에서 도메인 적응화를 적용한 여부에 따라 탐지결과가 뚜렷이 달라진 예시를 볼 수 있다. 이런 결과가 나온 이유는

CNN 모델이 객체의 형태보다는 질감에 더 가중치를 높게 두고 학습되는 경향이 있기 때문에[12] 미세조정하는 과정을 수행함으로써 합성이미지의 질감에 대해 학습한 모델의 가중치를 실제이미지의 질감에 적응시킨 결과라고 생각된다.

Fig. 12. examples of detected results

4. 결론

본 연구는 국방 분야 특성상 데이터 수집이 제한되는 특정 무기체계에 대한 객체탐지 모델 학습을 위해 시뮬레이션 게임엔진 하나만으로 다양한 합성 이미지를 생성하고 모델을 학습하였으며, 소량의 실사 이미지로 미세조정한 결과 성능이 향상됨을 확인하였다. 이를 통해, 도메인 적응화 기법 중 하나인 미세조정의 효용성 여부를 검증하였다.

이 연구를 통해 알 수 있는 두 가지는, 첫째로는 3D 모델의 형질을 변형할 수 있거나, 다양한 상황을 묘사할 수 있는 가상의 시뮬레이션 물리엔진을 구축한다면, 별도의 어플리케이션이나 이미지 합성기법을 사용하지 않아도 충분히 객체탐지 모델을 학습시킬 수 있다는 것이며 둘째로, 가상의 도메인에서 학습한 모델을 현실의 도메인에 적응시키는 과정이 모델의 성능을 향상시키는 데 큰 역할을 할 수 있다는 것이다.

본 연구의 제한사항으로는 합성이미지만으로 사전학습한 모델이 어느 정도의 일반화 능력을 지녔는지 비교 및 분석하지 못하였다는 점이다. 예를 들어, 사람의 경우에 합성이미지만으로 학습하여도 실제이미지에서 전차의 종류를 분류하는 것이 충분히 가능하지만 컴퓨터는 그렇지 못하다. 문제는, 왜 그렇지 못하는지 명확히 설명하기가 어렵다는 것이다. 여기서 발생한 도메인 격차가 객체탐지에 어떻게, 그리고 얼마나 영향을 주는지 분석이 가능하다면 이를 최적으로 해소하여 사람과 비슷하게 탐지할 수 있게끔 모델학습이 가능할 것이다. 차후에는 탐지해야 하는 대상에 따라 학습용 이미지와 모델의 매개변수, 구조 및 학습 횟수 등을 조정해나가면서 합성이미지로 사전학습한 모델의 일반화능력을 정량화하면서 그에 맞는 미세조정의 최적화에 대한 연구가 요구된다.

References

[1] DCS World, https://www.digitalcombatsimulator.com

[2] Liu, L., Ouyang, W., Wang, X., Fieguth, P., Chen, J., Liu, X., & Pietikäinen, M. Deep learning for generic object detection: A survey. International Journal of Computer Vision, 2019
DOI: https://doi.org/10.48550/arXiv.1809.02165

[3] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. You only look once: Unified, real-time object detection. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016
DOI: https://doi.org/10.48550/arXiv.1506.02640

[4] Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott Reed, Cheng-Yang Fu, Alexander C. Berg. SSD : Single Shot Mulitbox Detector. In Proceedings of the ECCV Conference on Computer Vision and Pattern Recognition, 2016
DOI: https://doi.org/10.48550/arXiv.1512.02325

[5] Ren, S., He, K., Girshick, R., & Sun, J., Faster r-cnn: Towards realtime object detection with region proposal networks. Advances in Neural Information Processing Systems, 28., 2015
DOI: https://doi.org/10.48550/arXiv.1506.01497

[6] Luotsinen J., Kamrani F., Lundmark L., Sabel J., Stiff H., Sandstorm V., Deep Learning with Limited Data: A Synthetic Approach. Swedish Defense Research Agency, 2021
DOI: https://apps.dtic.mil/sti/citations/AD1160019

[7] D. B. Kim, Y. D. Kim (2023). Ways to overcome the lack of defense AI learning data : Uilization of synthetic data, KIDA Defense Issues & Analysis, Vol. 1937

[8] Vanherle B., Moonen S., Van Reeth F., Michiels N., Analysis of Training Object Detection Models with Synthetic Data, 33rd British Machine Vision Conference 2022
DOI: https://doi.org/10.48550/arXiv.2211.16066

[9] Eversberg, L., Lambrecht, J., Generating Images with Physics-Based Rendering for an Industrial Object

Detection Task: Realism versus Domain Randomization. Sensors 2021, 21, 7901.
DOI: https://doi.org/10.3390/s21237901

[10] H. K. Lee, K. M. Lee, H. M. Yang, and S. Y. Oh, Applying FastPhotoStyle to Synthetic Data for Military Vehicle Detection, 20th International Conference on Control, Automation and Systems, 2020
DOI: https://doi.org/10.23919/ICCAS50221.2020.9268331

[11] S. W. Moon, Y. H. Kim, J. W. Lee, D. W. Nam, W. Y. Yoo, C. I. Kim, A Study on Improving the Performance of the Identification of Korean Warships Using Few-shot Learning through Domain Adaptation, Proceedings of the Korean Society of Electronics Engineers Conference, 2020

[12] Geirhos R., Ribisch P., Michaelis C., Bethge M., Wichmann A., Brendel W., ImageNet-trained CNNs are biased towards texture; increasing shape bias improves accuracy and robustness. tn Proceedings of the ICLR Conference on Computer Vision and Pattern Recognition, 2019
DOI: https://doi.org/10.48550/arXiv.1811.12231

이 경 재(Gyeong-Jae Lee) [준회원]

• 2016년 2월 : 육군사관학교 무기체계학과 학사
• 2022년 ~ 현재 : 국방대학교 국방과학학과 석사과정

〈관심분야〉
인공지능, 합성데이터, 무인전투체계

마 정 목(Jung-Mok Ma) [정회원]

• 2002년 2월 : 육군사관학교 운영분석 학사
• 2008년 2월 : 미국 펜실베니아주립대(PSU) 산업공학 석사
• 2015년 2월 : 미국 일리노이대(UIUC) 산업공학 박사
• 2015년 9월 ~ 현재 : 국방대학교 국방과학학과 교수

〈관심분야〉
국방 모델링 및 데이터분석학, 무기체계 획득관리