

Mask R-CNN을 이용한 이미지 합성 기반 데이터증강의 자주포 객체탐지 모델 성능향상 연구

채한결, 김수환*
국방대학교 국방과학학과

Image Synthesis-Based Data Augmentation using Mask R-CNN Self-Propelled Artillery Object Detection Model Performance Improvement Study

Han-Geul Chae, Su-Hwan Kim*
Division of Defense Science, Korea National Defense University

요약 국방 분야의 인공지능 기술 적용의 제한사항은 필요한 양질의 빅 데이터 확보가 어렵고, 확보한 데이터의 다양성이 부족하다는 점이다. 이러한 문제를 극복하기 위해 본 연구에서는 군 작전 환경에 맞는 이미지 데이터증강 방법을 연구한다. 먼저 객체는 '자주포'로 선정하고, 객체를 분리하여 특정한 배경에 합성하는 이미지 합성 기반 이미지 데이터증강방법을 통해 부족한 군 작전 환경에 대해 데이터증강 방법을 제안한다. 그리고 성능 확인을 위해 동계에서 식별된 자주포 이미지를 테스트 데이터로 하여, 동계가 아닌 환경에서 식별된 자주포 학습데이터를 기본 데이터증강 방법, 이미지 생성 기술 중 하나인 Cycle-GAN을 활용하여 데이터를 증강한 방법, 그리고 제시한 이미지 합성 기반 데이터증강 방법 총 3가지 방법을 활용하여 데이터를 증강한 후 YOLOv5 모델을 통해 객체탐지 성능을 비교한 결과 이미지 합성 기반으로 데이터를 증강한 학습 데이터셋을 사용한 경우가 mAP(0.5) 기준 97%로 가장 높은 성능을 보였다. 본 연구는 이미지 합성 기반 데이터증강 방법이 국방 분야 데이터의 다양성 부족 문제의 해결 가능성을 보이며, 이를 통해 무기체계 객체탐지모델 성능의 향상 방법을 제시하였다는 점에 의의가 있다.

Abstract The applications of AI technology have limitations in defense, such as the difficulty in obtaining sufficient high-quality big data and the lack of diversity in the acquired data. This study evaluated image data augmentation methods suitable for military operational environments to overcome these issues. First, the object selected is the "self-propelled artillery." By separating the object and synthesizing it into a specific background, an image synthesis-based data augmentation method is proposed to address the lack of data for military operational environments. Self-propelled artillery images identified in winter were used as test data to verify the performance. Three methods are used to augment the data: the baseline data augmentation method using self-propelled artillery training data identified in non-winter environments, data augmentation using Cycle-GAN, one of the image generation techniques, and the proposed image synthesis-based data augmentation method. The object detection performance was compared using the YOLOv5 model.

The results show that using the image synthesis-based data augmentation method with the augmented training dataset achieved the highest performance, with an mAP (0.5) of 97%. This study shows that image synthesis-based data augmentation can address the lack of diversity in defense sector data. In addition, it provides a method to improve object detection model performance in weapon system detection.

Keywords : Data-Augmentation, Object Detection, Mask R-CNN, Image Synthesis, Self-Propelled Artillery

*Corresponding Author : Su-Hwan Kim(Korea National Defense Univ.)

email: ksoohwan@gmail.com

Received August 17, 2023

Accepted November 3, 2023

Revised September 15, 2023

Published November 30, 2023

1. 서론

4차 산업 시대에 이르러 인공지능 관련 기술이 발달해 왔고, 군에서도 이를 접목하기 위해 노력하고 있다. 최근 국방혁신 4.0에서도 5가지 추진과제 중 하나로 'AI기반 핵심 첨단전력 확보'를 뽑으며 AI기반 무인·로봇 전투 체계 전력 확보를 위해 노력하고 있다. 또한, 국외에서도 국방 분야의 인공지능 기술사용에 대한 높은 수요를 인식하고 물류, 운송, 공격 분석, 통신 등의 분야에서 군사적으로 사용을 위한 방법을 찾고 있다[1].

이러한 인공지능 기술을 국방 분야에 적용하기 위해서는 인공지능 모델을 학습시키기 위한 다양하고 많은 양의 학습데이터가 필요하다. 하지만, 국방 분야의 특수성으로 인해 군 관련 데이터는 축적된 데이터의 양 자체도 적고, 데이터의 다양성 측면에서도 부족한 상황이다[2]. 학습데이터의 다양성은 매우 중요하다. 객체탐지 모델의 경우 모델 평가 시 학습된 데이터에 대해서는 좋은 성능을 확인할 수 있지만, 학습되지 않은 데이터로 성능 확인 시 학습한 데이터에 비해 성능을 예측하기 어렵다. 이러한 현상을 군 상황에 적용 시 전장 상황의 불확실성 및 예측 불가한 적의 활동을 고려할 때, 군에 실용화된 인공지능 모델들의 성능 또한 훈련 때와 실제 상황 때 달라질 수 있다는 우려를 낳을 수 있다. 이러한 점을 고려할 때 학습데이터의 다양성 부족은 실제로 인공지능 기술을 국방 분야에 적용하기 위해 가장 먼저 해결해야 할 과제 중의 하나이다.

본 연구에서는 군 무기체계 중 자주포를 객체로 선정하여 데이터셋을 구성하였고, 연구 목적상 적성 자주포 데이터를 수집하여 실험하는 것이 적절하나, 데이터 수집의 제한성으로 아군 자주포 데이터를 수집하였다. 다음으로 군 작전 환경 중 동계를 선정하여, 이미지 합성 기반 데이터증강 방법을 통해 동계 작전 중인 자주포의 객체탐지 성능을 높이기 위한 실험을 진행하였고, 기존 이미지 데이터증강 방법과 비교 분석하였다.

이미지 합성 기반 데이터 증강방법은 객체가 포함된 이미지에서 객체를 분리하여 원하는 배경에 합성하여 이미지의 다양성을 증가시키는 방법이며, 본 연구에서는 객체를 분리하는 과정에서 이전 연구들과는 다르게 Mask R-CNN 모델을 사용하여 사용의 소요시간을 단축하고, 용이성을 높였다.

본 연구의 구성은 2장에서 이미지 데이터증강과 무기체계 객체탐지 기존연구를 알아보고, 3장에서 본 연구에서 제시하는 이미지 합성 기반 데이터 증강방법에 대해

알아본다. 4장에서 실험 데이터셋의 구성과 제시한 데이터 증강방법과 성능 비교를 위한 기존 데이터 증강방법 결과를 보여준 후 5장에서는 데이터 증강방법에 따른 객체탐지 성능을 비교하고 마지막 6장에서 결론 및 추후 연구 방향을 제시한다.

2. 관련 연구

2.1 이미지 데이터증강

이미지 데이터증강은 추가적인 이미지 데이터 확보가 어려운 경우에 확보된 원본 이미지를 바탕으로 각종 변환을 사용하여 이미지 데이터 수를 증가시키기 위해 연구되는 분야이다.

조은희 등[3]은 산업 분야 생산과정에서 이미지 생성 기술인 적대적 생성 신경망(GAN) 기반 모델을 사용하여 부족한 학습데이터를 증강하였고, 김치용 등[4]은 자동화된 실시간 화재경보 시스템을 구현하기 위해 밝기조정, 블러링, 불꽃 사진 합성 3가지 방법을 활용해 학습데이터를 증강하였다.

군 무기체계의 객체탐지 성능을 높이기 위한 데이터 증강방법 연구로 황교성 등[5]은 적성 전차에 대한 객체탐지 성능을 향상하기 위해서 Mosaic Augmentation, SinGAN, RandAugmetn 3가지 방법의 데이터 증강방법의 조합을 실험하였고, 조선영[6]은 군용 차량이 수풀이나 위장막 등에 가려짐이 많이 발생한다는 점에 착안하여 가려짐을 갖는 데이터를 합성하여 학습데이터로 활용하였다. 임승균 등[7]은 4개국 전차 사진을 수집하였고, 안개와 흙먼지로 인해 객체 식별이 어려운 상황을 표현하기 위해 이미지에 노이즈를 가하는 데이터 증강방법을 사용하였다. 국외에서는 WILHELM ÖHMAN[8] 등이 군 무기 체계 데이터 확보를 위해 3D 군사 시뮬레이터 VBS3의 이미지를 활용해 합성데이터를 만들어 부족한 데이터를 증강하는 방법을 연구하였다.

기존연구들은 객체에 변화를 주어 실험하였고, 본 연구에서는 객체의 배경을 변경하여 데이터를 증강하였을 때의 다양성 증가 효과를 실험하였다.

3. 이미지 합성 기반 데이터증강

이미지 합성 기반 데이터 증강방법은 이미지 내 일부를 잘라내어 다른 이미지에 합성하는 Copy-Paste[9] 방

법을 활용하는 방법이다. 기존 Copy-Paste 방법에서는 1개의 이미지 데이터셋 내에서 객체 이미지와 배경이 될 이미지를 각각 선택하여 합성하였지만, 본 연구에서는 Fig. 1과 같이 객체가 선택되는 이미지와 배경이 될 이미지를 구분하여 데이터셋을 구성하여 데이터증강을 하였다. 데이터를 따로 구분한 이유는 군 특성상 획득 가능한 군 무기체계 이미지가 유사한 배경인 점을 고려하여, 무기체계 객체를 복사하여 새로운 배경에 합성하는 것이 데이터셋의 다양성을 늘리는 데 효과적이라고 판단하였다.

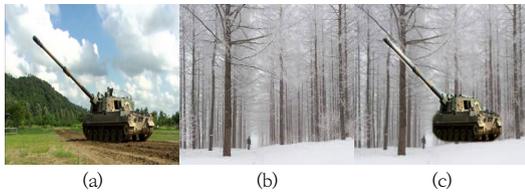


Fig. 1. Example of Image synthesis process
(a) Raw Image (b) Background Image (c) Synthesized Image

3.1 객체 추출을 위한 Mask R-CNN 학습

원본 이미지에서 객체를 추출하기 위해선 사전에 이미지 내 객체 라벨링(Labeling) 과정이 필요하다. 라벨링 방법은 사용하는 목적에 따라 객체 단위의 Bounding-Box 형태와 Pixel 단위의 Polygon 형태 등으로 나뉘는데 Bounding-Box의 경우 객체를 추출하였을 때 객체 주변의 배경이 함께 추출되어 새로운 배경에 합성되었을 때 부자연스럽기 때문에 객체의 외곽선을 따라 추출할 수 있는 Pixel 단위의 라벨링 방법을 사용하였다.

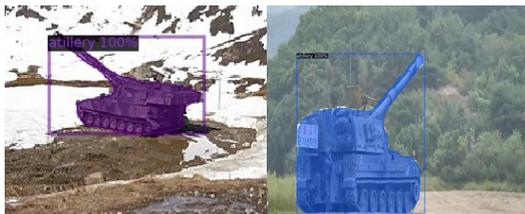


Fig. 2. Result of Mask-RCNN

추가로 추후 사용 간 이미지 데이터증강에 소요되는 라벨링을 시간을 단축하기 위해 본 연구에서는 Instance Segmentation 딥러닝 알고리즘의 하나인 Mask R-CNN[10]를 자주포 이미지에 대해 학습시킨 후 Mask R-CNN의 결과물로 나오는 Mask 데이터를 객체 추출을 위한 라벨링 데이터로 활용하였다.

Mask R-CNN의 구조는 Fig. 3과 같으며, 세부 과정

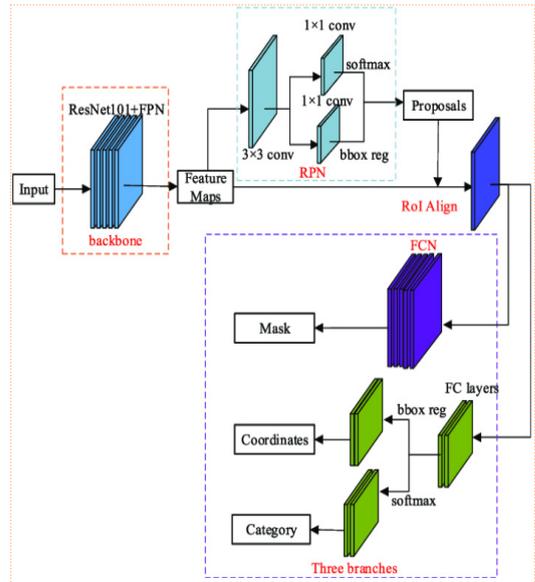


Fig. 3. The Structure diagram of Mask-RCNN algorithm.[10]

은 입력 이미지로부터 특성을 추출하는 Backbone을 거쳐, RPN(Region Proposal Network)을 통해 객체가 있을 가능성이 있는 후보 영역을 생성한다. 그 뒤 후보 영역을 일정한 크기로 조정된 뒤, RoI(Region of Interest) Align을 거쳐 후보 영역을 픽셀 단위로 정렬하고, 최종적으로 FCN(Fully Convolutional Network)을 FC Layer(Fully Connected Layer)을 거쳐 이미지 내 객체에 대한 분류결과와 Bounding Box 그리고 Mask를 출력한다.

Fig. 2는 학습된 Mask R-CNN 모델의 테스트 이미지에 대한 예시로서 객체 주변의 네모박스는 Bounding-Box이고, 객체 외곽선은 Pixel 단위로 객체의 Mask를 추출한 결과이다.

4. 데이터 구성

4.1 실험 목적 및 구성

실험 목적은 이미지 합성 기반 데이터 증강방법이 기존 이미지 데이터 증강방법보다 객체탐지 모델 성능향상에 효과적인지 확인하는 것이다.

먼저 실험 환경은 동계 환경으로 선정하였고, 선정 이유는 동계 작전은 군 작전 환경 중 중요성이 높지만, 기간적 제한 등으로 인해 타 환경보다 실제 데이터 획득이

어렵기 때문이다.

비교를 위해 사용한 데이터 증강방법으로는 기하학적 변화 위주의 기본 이미지 데이터 증강방법과 이미지 생성 기술인 적대적 생성 신경망(GAN) 기반 모델 중 하나인 Cycle-GAN을 활용한 데이터 증강방법 2가지를 사용하였다.

4.2 실험 데이터셋

실험에 사용할 무기체계는 기존 무기체계 객체탐지 연구에서 실험되지 않은 자주포로 선정하였고, 자주포 데이터는 한국군 자주포를 대상으로 인터넷에 공개된 이미지와 영상자료를 웹 크롤링하여 Fig. 4와 같이 287개를 수집하였다. 이 중 동계 데이터는 67개로 테스트 데이터로, 이 외의 220개의 데이터를 데이터 증강 후 학습데이터로 활용하였다.

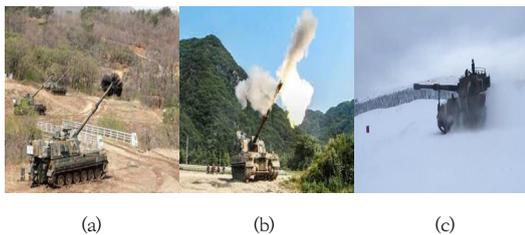


Fig. 4. Original Dataset
(a),(b) Train Data (c) Test Data

4.3 실험 데이터증강

실험에 사용한 데이터 증강방법은 이미지 합성 기반 데이터 증강방법과 4장 1절에서 제시한 2가지 증강방법 총 3가지이다.

Fig. 5의 (a)는 원본 이미지에 회전, 색상 변경, 일부 삭제 등의 기하학적 변화를 주는 기본적인 이미지 데이터 증강방법들을 적용한 결과이다.

특히 실험 목적상 동계 환경을 구현하기 위해 색상 변경은 Gray Scale을 사용하였고, 이미지 임의 영역을 검은색 네모박스로 가리는 Cutout[11] 방법을 통해 군 무기체계가 은 • 엄폐하여 가려진 경우를 표현하였다. (b)는 Cycle-GAN[12]을 사용하여 이미지 데이터 증강한 결과로, Cycle-GAN은 Source Domain X의 이미지 집합과 Target Domain Y의 이미지 집합을 학습하여, 최종적으로는 Domain X의 이미지를 Domain Y의 이미지로 변환하여 이미지를 생성하는 알고리즘이다. 본 연구에서는 원본 이미지를 동계 이미지로 변환을 하기 위해 'summer2winter_yosemite' 데이터셋으로 사전 학습

된 Cycle-GAN 모델을 사용하였다. 'summer2winter_yosemite' 데이터셋은 1540개의 여름 사진과 1200개의 겨울 사진으로 구성된 데이터셋이다. (c)는 3장에서 소개한 방법을 통해 이미지 데이터 증강한 결과로, 배경 이미지는 웹 크롤링을 통해 자주포 작전 지역과 유사한 100장의 동계 이미지를 수집하여 활용하였다.



Fig. 5. Result of image Augmentation
(a) Basic (b) Cycle-GAN (c) Image Synthesis

5. 실험 및 결과

5.1 실험 환경과 평가지표

실험은 Google Colaboratory pro를 활용하였고, 세부적인 실험 환경은 Table 1와 같다.

Table 1. Google colaboratory pro environment

GPU			CPU
Tesla T4			Intel(R) Xeon(R) CPU @ 2.20GHz
RAM	CUDA	Python	Framework
32GB	11.8	3.10.12	Pytorch 2.0.1

평가지표는 모델이 이미지 내에서 객체를 탐지한 정도를 평가하기 위해 일반적으로 객체탐지 모델의 평가지표로 사용하는 'IoU'와 'mAP'를 사용한다.

Table 2. Experiment Dataset

Experiment		#1	#2	#3	#4	#5	#6
Train set	Basic(B)	440	-	-	660	-	-
	Cycle-GAN(C)	-	440	-	-	660	-
	Image Synthesize(S)	-	-	440	-	-	660
Test set		67	67	67	67	67	67
Total		507	507	507	727	727	727

5.2 객체탐지 모델 학습

객체탐지 모델은 YOLOv5m을 사용하여 Table 2의 데이터셋으로 학습을 진행하였다.

실험 #1부터 실험 #3까지는 각 데이터 증강방법을 사용하여 원본데이터 220개를 2배수 증강한 학습데이터를 구성하였고, 실험 #4부터 실험 #6까지는 각 데이터 증강방법을 사용하여 원본데이터를 3배수 증강한 학습데이터를 구성하였다.

학습 간 Hyper Parameters는 사전학습된 YOLOv5 모델의 Default 값을 사용하되, Learning rate는 기존 0.01에서 0.005단위로 Tuning 과정을 거쳐 가장 높은 성능을 보인 값을 사용하였다. 최종적으로 이미지의 Input Size는 640 x 640, Learning rate는 initial learning rate를 0.005, final OneCycle learning rate를 0.0005, Momentum은 0.937, batch size는 16으로 설정하여 150epochs을 실시하였다.

5.3 실험 결과

동계 자주포 이미지의 테스트 데이터로 객체탐지 모델 탐지 결과는 Table 3과 같다.

먼저, 데이터 증강방법 간의 비교결과는 학습데이터를 2배수로 증강한 실험(#1~#3)과 학습데이터를 3배수로 증강한 실험(#4~#6) 모두 이미지 합성방법으로 학습데이터를 증강한 경우(#3, #6)가 다른 증강방법보다 모델 성능이 평가지표 mAP(0.5)를 기준으로 각각 91.2%와 97.0%로 가장 높게 확인되었고, Cycle-GAN을 통한 방법이 84.5%와 87.6%로 가장 낮은 성능을 보였다. 이를 통해 학습데이터로 확보하지 못한 새로운 환경에 대한 객체탐지가 필요할 경우 이미지 합성방법을 통한 데이터 증강방법이 가장 높은 성능향상 효과가 있음을 확인했다.

다음으로 증강 데이터양에 따른 비교결과는 Table 4에서 확인할 수 있듯이 이미지 합성방법의 경우가 가장 높은 성능향상 정도를 보였는데, 이는 이미지 합성방법이 비교방법들보다 과적합 방지 측면에서도 가장 우수하다는 것을 확인할 수 있다.

Table 3. Experiment Results

Experiment	mAP(0.5)	Precision	Recall
#1(B, 2X)	90.4 %	82.6 %	85.7 %
#2(C, 2X)	84.5 %	83.8 %	74.0 %
#3(S, 2X)	91.2 %	90.2 %	79.3 %
#4(B, 3X)	91.2 %	98.1 %	77.0 %
#5(C, 3X)	87.6 %	84.7 %	79.2 %
#6(S, 3X)	97.0 %	64.0 %	91.4 %

Table 4. Comparison of Performance Increase according to the amount of data augmentation

Type	Basic	Cycle-GAN	Image Synthesize
Comparison	#1, #4	#2, #5	#3, #6
Difference	0.8 %	3.1 %	5.8 %

Fig. 6는 각 증강방법의 차이를 시각적으로 확인하기 위해 테스트 데이터 중 학습데이터와 가장 차이가 있는 위장된 자주포 이미지의 객체탐지 결과로 이미지 합성방법을 통해 증강한 경우는 자주포 객체의 위치를 정확하게 탐지하고 0.5 이상의 신뢰도로 판단하여 객체탐지를 성공한 반면, 기본증강의 경우 자주포의 정확한 위치를 탐지해내지 못했고, Cycle-GAN 방법의 경우 위치는 탐지했지만, 낮은 신뢰도로 판단하는 차이를 보였다.

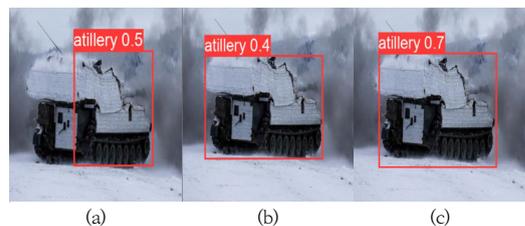


Fig. 6. Comparison of Object Detection Results
(a) Basic (b) Cycle-GAN (c) Image Synthesize

6. 결론

본 연구는 동계 환경 자주포에 대한 객체탐지 모델의 성능을 3가지 데이터 증강방법으로 학습데이터를 증강하고, 데이터증강 양을 2배와 3배로 나눠서 비교해본 결과 증강방법 중에선 제시한 이미지 합성방법으로 데이터를 증강한 경우가 기본 데이터 증강방법과 Cycle-GAN으로 데이터를 증강한 방법보다 성능이 더 높게 확인되었고, 데이터증강 양을 2배에서 3배로 증가시킨 경우에도 과적합으로 성능이 감소하지 않고 실험 중 최고 성능(97%)을 확인하였다.

본 연구의 의의는 이미지 합성 기반 데이터 증강방법을 위해 Mask-RCNN 모델을 활용하여 이미지 내 객체의 라벨링 데이터로 활용하여 자주포 데이터에 대해 라벨링 작업 시간을 단축했다는 점과 동계 환경과 같이 학습데이터 확보가 어려운 환경에 대해 객체탐지가 필요한 경우 이미지 합성 기반 데이터 증강방법이 다른 데이터 증강방법과 비교해 우수한 성능을 보임을 확인했다는 점이다.

본 연구의 제한사항으로는 자주포 단일 객체에 대해 실험을 진행하여 다른 무기체계가 혼재하는 경우나, 자주포 모델을 구분하는 것과 같이 다중 객체를 탐지하는 상황에 대해서 연구결과를 바로 적용하기 어렵다는 점과 동계 환경에 대해서는 이미지 합성 기반 데이터 증강방법이 효과적이라는 점을 실험 결과를 통해 확인했지만 적용하고자 하는 다른 작전 환경에 대해서도 제시한 데이터 증강방법이 다른 방법보다 효과적인지는 추후 연구를 통해 확인을 진행할 예정이다.

References

- [1] M. Bistrion, Z. Piotrowski, "Artificial Intelligence Applications in Military Systems and Their Influence on Sense of Security of Citizens", *Electronics*, Vol.10, No.7, pp. 871, 2021.
DOI: <https://doi.org/10.3390/electronics10070871>
- [2] D. B. Kim, Y. D. Kim, Ways to overcome the lack of defense AI learning data:Utilization of synthetic data, KIDA, 2023, Available From: <https://www.kida.re.kr/frt/board/frtNormalBoardDetail.do?sidx=382&idx=2000&depth=3&searchCondition=title&searchKeyword=&pageIndex=2&lang=kr> (accessed July. 05, 2023)
- [3] E. H. Cho, S. M. Jin, B. H. Jeon, I. K. Park, "Augmentation of Defect Image Data using GAN", *Journal of the Institute of Electronics and Information Engineers*, Vol.59, No.10, pp. 98-108, 2022.
DOI: <https://doi.org/10.5573/ieie.2022.59.10.98>
- [4] C. Y. Kim, H. S Lee, K. Y. Lee, "Implementation of a Deep Learning based Realtime Fire Alarm System using a Data Augmentation", *Journal of IKEEE*, Vol. 26, No. 3, pp.136-142, 2022.
DOI: <https://doi.org/10.7471/ikeee.2022.26.3.468>
- [5] K. Hwang, J. Ma, "Improvement of Object Detection Performance for Enemy Tanks Using the Combination of Data Augmentation Models," *Korean Journal of Computational Design and Engineering*, Vol. 27, No. 2, pp. 148-159, 2022.
DOI: <https://doi.org/10.7315/CDE.2022.148>
- [6] S. Cho, "Robust Military Vehicle Detection under Partial Occlusion with Synthetic Data," *KIISE Transactions on Computing Practices*, Vol. 27, No. 11, pp. 519-530, 2021.
DOI: <https://doi.org/10.5626/KTCP.2021.27.11.519>
- [7] S.K. Lim, D. S. Kang, "Identifications and Evaluation of Tank Nationality using YOLO Algorithm," *KIISE Transactions on Computing Practices*, Vol. 27, No. 12, pp. 555-562, 2021.
DOI: <https://doi.org/10.5626/KTCP.2021.27.12.555>
- [8] W. Öhman, *Data augmentation using military simulators in deep learning object detection applications*, Master's thesis, School of Electrical Engineering and Computer Science, Sweden, pp. 3, 2019.
- [9] G. Ghiasi, Y. Cui, A. Srinivas, R. Qian, T. Y. Lin, E. D. Cubuk, Q. V. Le, B. Zoph, "Simple Copy-Paste Is a Strong Data Augmentation Method for Instance Segmentation", *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 2918-2928, 2021.
DOI: <http://dx.doi.org/10.1109/CVPR46437.2021.00294>
- [10] Z. Zhou, J. Chen, X. Wou, "Detection and Classification of Multi-Magnetic Targets Using Mask-RCNN", *IEEE ACCESS*, Vol. 8, pp. 187202-187207, 2020.
DOI: <http://dx.doi.org/10.1109/ACCESS.2020.3030676>
- [11] T. Devries, G. W. Taylor, "improved Regularization of Convolutional Neural Networks with Cutout", *arXiv*, 2017.
DOI: <https://doi.org/10.48550/arXiv.1708.04552>
- [12] J.Y. Zhu, T. Park, P. Isola, A. A. Efros, "Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks", *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, pp. 2223-2232, 2017.
DOI: <http://dx.doi.org/10.1109/ICCV.2017.244>

채 한 결(Han-Geul Chae)

[준회원]



- 2015년 2월 : 육군사관학교 수학과 학사
- 2022년 ~ 현재 : 국방대학교 국방과학학과 석사과정

<관심분야>

인공지능, 최적화

김 수 환(Su-Hwan Kim)

[정회원]



- 1996년 2월 : 육군사관학교 화학과 석사
- 2004년 2월 : 한국과학기술원 산업 및 시스템공학과 공학석사
- 2103년 3월 : Texas A&M University 산업공학 박사
- 2013년 ~ 현재 : 국방대학교 국방과학학과 교수

<관심분야>

조합 최적화, 인공지능, 비용추정