

SinGAN을 활용한 군사장애물 데이터 부족 문제 해결 및 실증 연구

황재민, 마정목*
국방대학교 국방과학학과

An Empirical Study on the Problem of Lack of Military Obstacle Data Using SinGAN

Jae-Min Hwang, Jung-Mok Ma*
Department of Defense Science, Korea National Defense University

요약 최근 자율주행기술이 발전하면서, 지상 기동무기체계에도 자율주행기술이 적용되는 등 무인화 및 인공지능 기술이 도입되고 있다. 특히 지상 기동무기체계 중 공병 기동장비가 무인화될 시, 군사장애물의 극복방법을 판단하는 공병장비의 특수성 때문에 기동로 상 군사장애물을 정확하게 분류하는 인공지능 기술이 요구된다. 인공지능이 군사장애물을 정확하게 분류하기 위해선 군사장애물에 대한 이미지 데이터가 확보되어야 하나 보안상 다량의 데이터 확보가 제한된다. 때문에 이 연구는 군사장애물 데이터를 증강시키기 위해서 적대적 생성모델중 하나의 이미지로 다량의 이미지를 생성하는 SinGAN(Single Generative Adversarial Network)모델을 활용해 군사장애물 데이터의 부족 문제를 해결하였다. 또한 연산량이 많아 외부환경에서 CNN(Convolutional Neural Network) 기술을 적용하기 어려웠던 문제를 극복한 경량화된 딥러닝 모델인 모바일넷의 구글 티처블 머신을 통해 분류 정확도가 개선되는지를 실증하였다.

Abstract Recent developments in autonomous driving technology have resulted in the introductions of unmanned and artificial intelligence technologies, such as ground-based maneuvering weapon systems. In particular, when ground-based maneuvering weapon systems are unmanned, artificial intelligence technologies that accurately classify military obstacles are required to determine how to overcome these obstacles. To enable artificial intelligence to accurately classify military obstacles, image data on military obstacles must be secured. However, this is limited by security concerns. Therefore, we attempted to solve this problem using the SinGAN (Single Generative Adversarial Network) model, which generates large numbers of images to augment military obstacle data. This model also shows whether classification accuracy is improved by the Google Teachable Machine of the MobileNet model, a lightweight deep learning model that overcomes the difficulty posed by the high computation requirements of CNN(Convolutional Neural Network) technology application in an external environment.

Keywords : Data Augmentation, SinGAN, Military Obstacle, Deep Learning, Google Teachable Machine

1. 서론

최근 국방과학연구소에서 딥러닝 기반 인공지능 기술을 활용한 자율주행 기술 개발에 성공했다고 밝혔다[1].

해당 기술을 토대로 현재 운용중인 지상 기동무기체계에 대해 인공지능 기술을 확대 적용할 수 있다. 특히 지상 기동무기체계 중 공병 기동장비는 적의 장애물과 화력이 밀집되어있는 위험지역에 가장 먼저 진입하다보니 적 화

*Corresponding Author : Jung-Mok Ma(Korea National Defense Univ.)

email: jxm1023@gmail.com

Received November 3, 2022

Accepted January 6, 2023

Revised November 30, 2022

Published January 31, 2023

력자산에 노출되기 쉽다. 이러한 승무원의 생존성 보장 문제를 해결하기 위해 인공지능 기술을 적용할 필요가 있다.

인공지능 기술을 적용할 공병 기동장비로 현대 로템에서 개발한 K-600 장애물개척전차를 꼽을 수 있다. 장애물개척전차는 장애물의 종류에 따라 굴착, 도징, 파쇄 등으로 장애물을 개척하는 능력을 보유하고 있다. 장애물개척전차에 인공지능 기술을 도입한다면 장애물의 종류를 분류하는 컴퓨터 비전(computer vision) 능력이 요구된다.

장애물을 명확하게 분류하는 컴퓨터 비전 능력이 구축되기 위해선 학습데이터가 다량으로 필요하다. 하지만 군사 목적의 데이터이다 보니 보안상 다량의 데이터를 확보하기 어렵고, 군사장애물이란 특성상 실제로 구현하기 제한되는 점이 많다.

군사 분야에서 적 전차의 이미지 데이터를 딥러닝 기술을 적용해 증강한 사례[2]는 있었으나 군사장애물 데이터를 증강한 사례는 없었다. 때문에 부족한 군사장애물 데이터를 확보하기 위해 딥러닝 기술로 데이터를 증강하는 본 연구를 실시하였다. 여기서 사용한 딥러닝 기술은 적대적 생성모델(GAN, Generative Adversarial Network, 이하 GAN) 중 하나의 이미지 데이터를 다량의 데이터로 증강할 수 있는 SinGAN(Single GAN, 이하 SinGAN) 모델이다. 해당 모델로 증강된 데이터셋을 생성해볼 것이다.

이후 증강시킨 데이터셋과 기존 데이터셋으로 군사장애물 분류모델을 구축 및 학습시키고, 실제 현장에서 정확도가 얼마나 향상되는지 RC카(RC-car)를 이용해 실증해볼 것이다.

2. 관련 연구

2.1 이미지 데이터 증강

이미지 데이터 증강기법은 모델의 성능 향상 목적으로 학습 이미지 데이터 수량을 증가시키는 방법이다. 다시 말하자면, 새로운 데이터를 수집하는 것이 아닌 기존의 데이터를 활용해 학습 데이터 수를 늘리는 방법이다.

증강방법으로는 크게 아래 Fig. 1과 같이 기본 이미지 조작방법(basic image manipulations)과 딥러닝 접근 방법(deep learning approaches)으로 구분할 수 있다 [3].




Fig. 1. Methods of data augmentation

기본 이미지 조작 방법은 기존 이미지에 반전, 자르기, 회전 등의 기법을 활용해 이미지 자체의 변형보다는 기존 이미지의 기하학적 변형을 줌으로써 데이터를 증가시키는 방법이다. 딥러닝 접근방법은 인공신경망을 적용해 기존 이미지 자체를 변형하여 새로운 이미지를 생성하는 방법으로 GAN 모델을 활용한 방법이 대표적이다. 기본적으로 이미지 데이터 증강방법은 기본 이미지 조작 방법을 적용해서 딥러닝 모델의 성능을 향상시킨다. 대표적인 라이브러리로 Imgaug, Randaug, Albumentation 등이 있다[4].

위 방법을 사용한 대표적인 사례로 Gonçalo Marques[5]는 코로나 환자 CT 이미지를 Albumentation으로 증강하여 학습데이터로 활용하는 방안을 연구하였다. 또한 Vung Pham[6]은 도로상 크랙 또는 손상된 부분을 감지 및 분류하는 모델을 구축하기 위해 데이터 증강을 실시하였다.

하지만 단순히 기하학적 변형만으로는 데이터 증강에 한계가 있고, 결국 데이터 부족 문제에 직결하게 된다. 그래서 본 연구에서는 데이터 증강방법 중 딥러닝 접근 방법을 활용할 것이고, 딥러닝 증강방법인 GAN 모델 중 원본 데이터를 확보하기 어려운 군사 분야에서 활용가능한 SinGAN 모델을 활용하여 군사장애물 데이터 부족 문제를 해결할 것이다.

2.2 SinGAN 모델

GAN 모델은 데이터를 생성하는 생성자(generator) 신경망과 생성된 데이터와 실제 데이터를 비교하여 진위 여부를 판단하는 구별자(discriminator) 신경망으로 구성된다. 이 두 신경망간 경쟁하여 생성되는 랜덤변수(random variable)가 실제 원본 이미지 데이터와 비슷한 분포를 보이게 된다. 결국 위 분포가 구별자를 속여 내쉬균형(nash equilibrium)의 상태와 같이 더 이상 이점이 없는 균형점에 도달하게 되고, 최종적으로 유사한 이미지 데이터를 생성하게 된다[7]. 여기서 파생되어 DCGAN, WGAN, CycleGAN, StarGAN 등 다양한

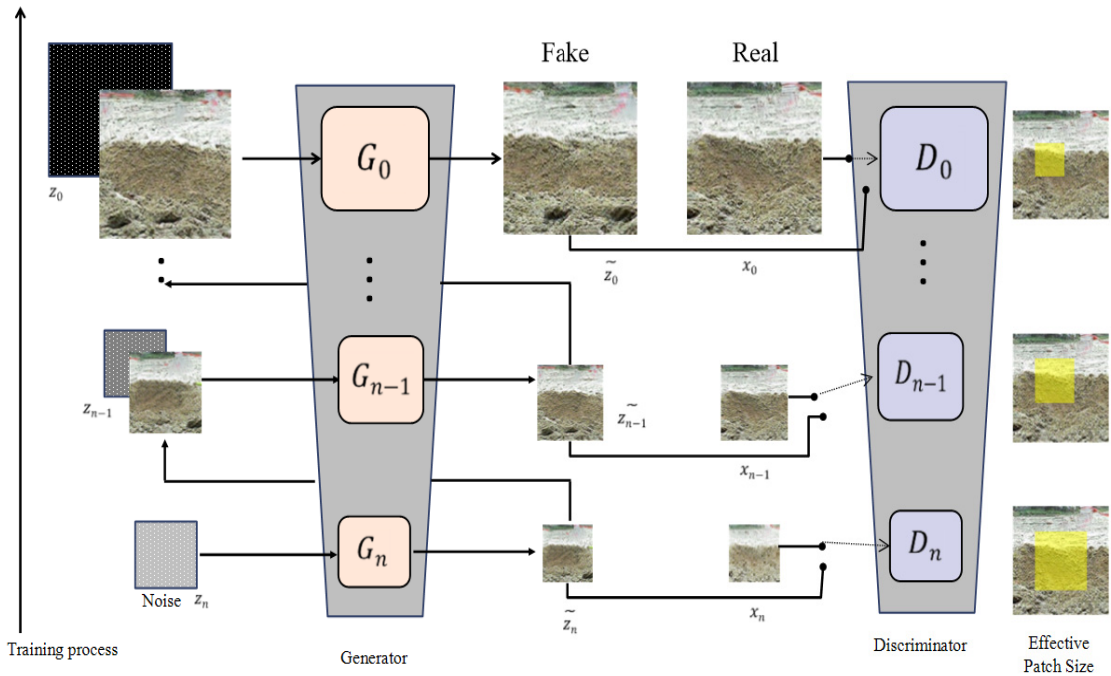


Fig. 2. SinGAN pipeline[8]

GAN 모델로 발전하였다.

다만, 위에서 제시된 GAN 모델들은 학습하기 위해 데이터가 다양으로 확보되어야 한다. 하지만, 군사장애물 같이 데이터 확보에 제한이 있는 경우엔 적용하기가 어렵다. 그래서 이를 해결하기 위해 하나의 이미지 데이터로 다량의 이미지 데이터를 생성할 수 있는 SinGAN 모델을 활용하였다.

SinGAN 모델은 GAN 모델의 알고리즘 중 하나로 위의 Fig. 2와 같이 생성자와 구별자를 활용한 원리는 동일하지만, 여러 개의 생성자와 구별자를 쌓아 반복적으로 이미지를 학습한다는 점에서 타 모델과는 차이가 있다. 때문에 다량의 원본 데이터가 필요했던 기타 GAN 모델과는 달리 SinGAN 모델은 하나의 이미지로 유사한 여러 이미지를 생성할 수 있다는 장점을 가지고 있다. 또한 아래에서 위로 올라갈수록 저해상도에서 고해상도로 순차적으로 학습해서 아래에서부터 이미지의 큰 부분을 학습하고, 위로 갈수록 업샘플링(upsampling)하면서 미세한 부분을 학습한다[8]. 이는 원본 데이터를 획득하기 어려운 군사 데이터에서 활용하기에 적합하다.

위 방법을 사용한 사례로 손현승[9]은 SinGAN 딥러닝 모델을 이용해 양식장에서 질병 확산을 막기 위한 낚치의 질병 이미지 패턴을 증강해 데이터를 생성하였다.

권주원[10]은 SinGAN 모델을 사용해 암 조직의 병리 데이터를 확장시켜 모델의 학습성능을 향상시키는 방안을 연구하였다. 또한 황교성[2]은 군사적인 목적으로 적성 전차 이미지를 증강시켜 객체 탐지 모델인 YOLOv5s를 통해 모델 성능을 향상시키는 연구를 실시하였다.

3. 데이터 증강 및 모델 구축

3.1 군사장애물 분류 및 데이터 증강

군사장애물 분류는 Fig. 3과 같이 장애물개척전차의 극복능력을 고려해 구축장애물, 지뢰지대, 도로대화구, 그리고 기동로로 분류할 수 있게 4개의 클래스로 구성하였다. 특히 구축장애물은 대부분 낙석 장애물이기 때문에 낙석으로 재정의하였다[11].

아래와 같은 클래스를 기준으로 인터넷 상에서 남·북한 도로사진, 장애물 이미지 데이터를 수집하였다. 그 결과, 기동로 102개, 낙석 47개, 지뢰지대 133개, 도로대화구 69개 데이터를 합한 351개의 데이터를 획득하였고, 각 클래스별로 SinGAN 모델을 활용해 최종 500개씩 목표로 데이터 증강을 실시하여 총 2,000개의 이미지 데이터를 생성하였다.

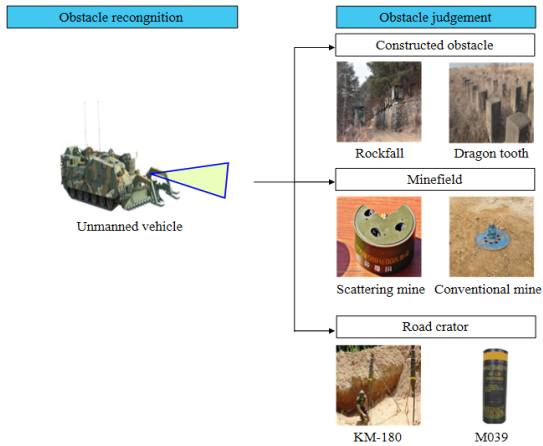


Fig. 3. Criteria of obstacle classification[11]

데이터 증강간 학습환경은 구글 코랩 프로(google colaboratory pro)를 활용하였고, 컴퓨터 환경은 아래 Table 1과 같다.

Table 1. Computer environment

Section	Spec
CPU	Tesla P100
GPU	Geforce RTX 3060 Ti
Python	3.7.14
RAM	16.00GB

3.2 SinGAN 모델을 활용한 데이터 증강방법

SinGAN 모델을 활용해 수집된 각각의 군사장애물 데이터와 기동로 데이터를 증강을 실시하였다.

SinGAN 모델은 아래 Fig. 4와 같이 생성자 내부에 5개 층으로 구성되어있고, n쌍의 생성자, 구별자 쌍이 있어 한 이미지를 학습시킬 경우 많은 시간이 소요된다.




Fig. 4. Structure of SinGAN Generator[8]

여기서 n 은 이미지의 학습정도에 따라 달라지기 때문에 특정한 수로 정의하기 어렵다. 또한 생성되는 샘플(sample) 중 일부는 일그러지는 이미지로 생성되다보니 모두 정상적인 데이터가 생성되지 않는다. 그래서 하나의 데이터 이미지로부터 많은 샘플을 생성할 경우, 시간과 데이터 질적 측면에서 효율적인 데이터 구성을 하기 제한된다. 따라서 효율적인 데이터 구성을 위해 하나의 데이터로 아래 Fig. 5와 같이 256x256 크기의 50개 샘플을 생성하였다.




Fig. 5. Image augmentation using on SinGAN

기동로, 지뢰지대, 도로대화구는 하이퍼파라미터인 스케일(scale)을 n 으로 설정할 경우 그 형태를 잘 유지하여 생성 가능하나 낙석장애물은 아래 Fig. 6과 같이 일그러지게 생성되었다.



Fig. 6. Rockfall obstacle generated on scale n

여기서 스케일이란 어느 생성자, 구별자 쌍에서부터 학습을 시작할 것이라는 SinGAN의 하이퍼 파라미터이다. 이는 기타 장애물보다 낙석 장애물이 정형화된 조각 단위로 파괴되어 장애물의 형태를 나타내기 때문에 보다 높은 단계의 생성자에서부터 학습을 시작하여 낙석장애물의 어느정도 형상을 유지한 상태로 미세한 조각 부분에 대한 학습을 시작해야 다음 장에 제시된 Fig. 7과 같이 올바르게 생성된다. 스케일을 $n-1$ 로 설정했을 경우에도 동일한 현상이 식별되었다. 그래서 낙석장애물 데이터를 생성할때는 스케일을 $n-2$ 이하로 설정해서 타 장애물보다 2단계 위의 생성자와 구별자 단계에서부터 학습

을 시작하게 하여 정상적인 형태를 유지할 수 있도록 하였다.



Fig. 7. Rockfall obstacle generated on scale n-2

3.3 장애물 분류모델 구축

실제로 군사장애물 분류모델에 증강된 군사장애물 데이터를 학습한 사용하며 성능이 향상되는지 살펴보았다. 본 연구에서는 실제 야외에서 모델이 향상되었는지를 실증하기 때문에 저성능 모바일 환경에서도 사용가능한 Google Teachable Machine 프로그램을 활용하였다. Google Teachable Machine은 CNN 기반의 MobileNet 알고리즘을 활용한 프로그램이다. 모델의 성능은 기타 CNN모델과 동일하지만, 연산량을 대폭 줄여 하드웨어 환경이 열악한 야외에서 사용하기 적합하다. 또한 구축한 모델을 모바일 링크로 내보낼 수 있고, 실증간 사용할 RC카가 촬영한 이미지를 현장에서 즉각적으로 분류하는지 살펴볼 수 있는 장점을 가지고 있기 때문에 본 실증간에 해당 프로그램을 사용하였다.

실증에 앞서 모델은 원본 데이터 351개만 있는 기본 데이터셋(dataset)과 증강된 데이터까지 포함된 2,000개로 학습한 증강 데이터셋을 구축한다. 구축한 각각의 데이터셋을 토대로 모델의 성능을 최적화하기 위해 하이퍼 파라미터 튜닝 작업을 실시한다. 이 때, Google Teachable Machine은 배치사이즈(batch size)를 16, 32, 64, 128, 256, 512로만 조작할 수 있는 특성이 있기 때문에 하이퍼 파라미터 튜닝으로 그리드 서치(grid search) 방법을 적용하였다[12]. 그리드 서치란 하이퍼 파라미터에 넣을 수 있는 값들을 순차적으로 넣어 비교 분석하여 가장 낮은 테스트 로스(test loss)값을 갖는 모델의 하이퍼 파라미터를 도출하는 방법이다.

에포크(epoch)는 150기준으로 학습하되, 과소적합(underfitting)이 나올 경우 에포크를 500, 1000으로 늘려서 최적의 에포크 수를 탐색하였다. 그리드 서치 방식으로 하이퍼 파라미터를 조정된 결과 기본 데이터셋은 아래 Table 2와 같은 값이 나타나게 되었고, 증강 데이

터셋은 아래 Table 3과 같이 나오게 되었다. 이를 통해 기본 데이터셋은 에포크 58, 배치 사이즈 16, 학습률(learning rate) 0.001로 설정할시 가장 낮은 테스트 로스값이 나오고, 증강 데이터셋은 에포크 75, 배치 사이즈 16, 학습률 0.0001로 설정할 시 가장 낮은 테스트 로스값이 나오게 됨을 알 수 있다.

Table 2. Value of hyperparameter on basic dataset model

B / L / E	Test accuracy	Min. test loss	Optimal epoch
16/0.001/150	0.9812	0.1027	58
16/0.0001/150	0.9571	0.1821	109
16/0.00001/150	U	U	U
16/0.00001/500	0.8998	0.3872	327
32/0.001/150	0.9189	0.1271	9
32/0.0001/150	0.9372	0.2183	39
32/0.00001/150	U	U	U
32/0.00001/500	0.9023	0.3129	387
64/0.001/150	0.9717	0.1513	80
64/0.0001/150	0.9635	0.1728	139
64/0.00001/150	U	U	U
64/0.00001/500	0.9027	0.2672	298

* B : Batch size / L : Learning rate / E : Epoch / U : Underfitting

Table 3. Value of hyperparameter on augmented dataset model

B / L / E	Test accuracy	Min. test loss	Optimal epoch
16/0.001/150	0.9802	0.0659	11
16/0.0001/150	0.9736	0.0590	75
16/0.00001/150	U	U	U
16/0.00001/500	0.9736	0.0790	195
32/0.001/150	0.9802	0.0636	8
32/0.0001/150	0.9736	0.0913	61
32/0.00001/150	U	U	U
32/0.00001/500	0.9802	0.0862	273
64/0.001/150	0.9802	0.0887	16
64/0.0001/150	U	U	U
64/0.0001/500	0.9736	0.0678	250
64/0.00001/150	U	U	U
64/0.00001/500	U	U	U
64/0.00001/1000	0.9736	0.0644	702

* B : Batch size / L : Learning rate / E : Epoch / U : Underfitting

위에서 도출한 최적의 하이퍼 파라미터로 각각 모델을 85 % 비율의 데이터로 학습을 시킨 후, 15 % 비율의 데이터로 모델의 정확도를 확인해보았다. 아래 Table 4와 같이 기본 데이터셋 같은 경우 클래스별 정확도가 최소 88 % 이상의 정확도가 나온다. 증강 데이터셋 같은 경우 클래스별 정확도가 최소 98 % 이상의 정확도가 나온다.

데이터를 증강시킨 결과, 최소 정확도가 기본 데이터 셋에 비해 낙석과 도로대화구는 10 %, 지뢰지대는 5 %가 증가함을 알 수 있다.

Table 4. Accuracy of dataset 1

Class	Accuracy(%)		Rate of increase(%)
	Basic dataset	Augmented dataset	
Manuever road	100	100	0
Rockfall	88	98	+10
Minefield	95	100	+5
Road crator	88	98	+10

4. 모델 실증 및 결과 분석

4.1 실험환경 및 가정

3.3절에서 구축한 모델이 실제 현장에서 군사장애물을 정확하게 인식하는지 무인 장애물개척전차로 가정한 RC카에 카메라를 장착해 실험하였다. 실험한 사용한 RC카는 아래 Table 5와 같은 성능을 보유하고 있다.

Table 5. Spec of RC-car

Width	Length	Height	Max velocity
19.5 cm	32 cm	12 cm	25 km/h
Camera	300 thousand pixel(640×480)		

또한 실제 도로낙석을 떨어뜨려 실험되기 제한되서 RC카 시점에서 동일한 시각을 보여주는 시멘트 블록을 사용하였다. 그리고 일반적으로 실제 도로낙석이 6~8개 정도의 낙석으로 구성되어 있어 동일하게 6~8개 시멘트 블록을 사용하였다. 또한 실제 지뢰를 매설해 실험하기 제한되어 지뢰와 동일한 모양으로 군에서 운용되고 있는 대인 및 대전차 교보재 지뢰를 활용하여 지뢰지대를 묘사하였다.

실험에 앞서 최적의 하이퍼 파라미터로 학습시킨 기본 데이터셋과 증강 데이터셋을 각각 하이퍼링크로 생성하고 스마트폰 환경으로 이동하여 실행한다. RC카 카메라 앱과 스마트폰을 연동한 상태로 각각의 데이터셋 모델들을 실행하면서 현장에서 분류 정확도를 살펴보는 방식으로 실험을 진행하였다.

실제 실험장소에는 아래 Fig. 8과 같이 세 개의 군사장애물로 구성하였다. 특히 실험하는 도로폭은 2차선 도

로로 가정하여 실험하는 RC카 폭의 2배인 40 cm로 구성하였다.




Fig. 8. Environment of experiment

4.2 실험결과

RC카 카메라를 활용해 3개의 군사장애물을 각각 10장씩 촬영해 정확하게 분류하는지 살펴보았다. 10장의 사진은 차가 왕복하면서 다양한 각도에서 촬영하며 추출하였고, 현장에서 모바일상의 데이터셋별 링크를 연결하여 각각 정확도를 확인하였다.

각각의 이미지 데이터를 모델별로 검증해본 결과, 아래 Table 6과 같이 각 클래스별 평균 정확도 값이 도출되었다. 도출된 값을 보면 4개의 클래스 모두 분류 정확도가 증가한 것을 알 수 있다.

Table 6. Comparison of basic dataset and augmented dataset

Class	Accuracy(%)		Rate of increase(%)
	Basic dataset	Augmented dataset	
Manuever road	90.3	99	+8.7
Rockfall	93.7	97.1	+3.4
Minefield	98.4	98.7	+0.3
Road crator	87.1	98.3	+11.2

특히, 기동로와 도로대화구 같은 경우는 기본 데이터셋에서 각각 1개씩 이미지가 30% 이하의 낮은 인식률을 보이는 이미지가 있어 평균 정확도가 떨어지는 것을 살펴볼 수 있지만, 증강 데이터셋에서는 군사장애물 데이터를 증가하여 모든 클래스에서 분류 정확도가 95 % 이

상의 값이 도출되었다. 또한 증강 데이터셋에서는 검증 데이터 중 분류 정확도가 90 % 이하로 나타나는 데이터는 없었다. 이는 SinGAN 모델을 활용해 군사장애물 데이터를 증강하는 방법이 모델 향상에 기여한다는 것을 알 수 있다.

5. 결론

본 연구는 딥러닝 기술을 적용한 군사장애물 분류모델의 데이터 부족 문제를 해결하기 위해 군사장애물 데이터 증강을 실시하였다. 또한 해당 모델을 실증하여 군사장애물 데이터 증강의 효과성을 살펴보았다. SinGAN 모델을 활용해 획득하기 어려운 군사장애물 데이터 증강이 가능하였고, 증강된 데이터가 분류 모델의 성능을 높일 수 있음을 확인하였다. 또한 군사장애물 데이터 증강시, 장애물 종류에 따라 스케일 파라미터를 다르게 적용해야 데이터 증강이 원활하게 이루어짐을 확인할 수 있었다.

하지만 기존 데이터와 완전히 다른 새로운 데이터를 생성하는 데는 제한사항이 있었고, SinGAN 모델을 활용해서 고품질의 이미지 데이터를 획득하기 어려움을 알 수 있었다.


향후 군사분야에서 SinGAN 모델을 적용하면 획득하기 어려운 적 무기체계 데이터셋을 증강시킬 수 있고, 적 무기체계를 식별하는 객체 탐지 모델의 성능을 향상시킬 수 있는데 기여할 수 있을 것이다. 또한 자율주행 무기체계의 학습간 사용되는 데이터를 증강하여 유·무인 복합체계 성능 개선 등 군사 분야 데이터 부족 문제를 해결할 수 있을 것이다.

References

- [1] B. N. Jung, Defense Science Research Institute Development of 'Autonomous Driving in Dangerous Places' Technology... Use in Weapons Systems[Internet]. Yunhap News, c2022[cited 2022 May 24], Available From: <https://www.yna.co.kr/view/AKR20220524040400504?input=1195m> (accessed Oct. 2, 2022)
- [2] K. S. Hwang, J. M. 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, Jun. 2022. DOI: <https://doi.org/10.7315/CDE.2022.148>
- [3] Connor Shorten, Taghi M. Khoshgftaar, "A Survey on Image Data Augmentation for Deep Learning", *Journal of Big Data*, 6(1), pp.1-48, Jul. 2019. DOI: <https://doi.org/10.1186/s40537-019-0197-0>
- [4] Alexander Buslaev, Vladimir I. Iglovikov, Eugene Khvedchenya, Alex Parinov, Mikhail Druzhinin, Alexandr A. Kalinin, "Albumentations: Fast and Flexible Image Augmentations", *Information*, 11(2), Feb. 2020. DOI: <https://doi.org/10.3390/info11020125>
- [5] Gonçalo Marques, Deevyankar Agarwal, Isabelde la Torre Díez, "Automated Medical Diagnosis of COVID-19 through EfficientNet Convolutional Neural Network", *Applied Soft Computing*, 96, pp.1-11, Nov. 2020. DOI: <https://doi.org/10.1016/j.asoc.2020.106691>
- [6] Vung Pham, Chau Pham, Tommy Dang, "Road Damage Detection and Classification with Detectron2 and Faster R-CNN", *2020 IEEE International Conference on Big Data, Computing*, Oct. 2020. DOI: <https://doi.org/10.1109/BigData50022.2020.9378027>
- [7] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, Y. Bengio, "Generative Adversarial Nets", *arXiv*, Jun. 2014. DOI: <https://doi.org/10.48550/arXiv.1406.2661>
- [8] T. R. Shaham, T. Dekel, T. Michaeli, "Singan: Learning a Generative Model from a Single Natural Image", *Proceedings of the IEEE/CVF International Conference on Computer Vision*, IEEE, Seoul, South Korea, pp 4570-4580, Nov. 2019. DOI: <https://doi.org/10.48550/arXiv.1905.01164>
- [9] H. S. Son, H. S. Choi, "Image Augmentation of Paralichthys Olivaceus Disease Using SinGAN Deep Learning Model", *Journal of Korea Contents*, 21(12), pp 322-330, Dec. 2021. DOI: <https://doi.org/10.5392/JKCA.2021.21.12.322>
- [10] J. W. Kwon, K. J. Gii, S. J. Kim, Y. C. Jung, S. C. Kwon, "Study of Pathology Data Augmentation Technique Using SinGAN", *IEIE*, Jeju, South Korea, pp 995-998, Aug. 2020.
- [11] J. M. Hwang, J. M. Ma, "A Design and Demonstration Study of Military Obstacle Classification Model Using Google Teachable Machine", *Korean Journal of Computational Design and Engineering*, Vol.27, No.2, pp 137-147, Jun. 2022. DOI: <https://doi.org/10.7315/CDE.2022.137>
- [12] Thisted, R.A., 1988, Elements of Statistical Computing, p448, Chapman & Hall, 1988, pp.154-258.

황재민(Jae-Min Hwang)

[준회원]



- 2013년 2월 : 육군사관학교 무기시스템 공학과 (무기시스템 공학 학사)
- 2021년 2월 ~ 현재 : 국방대학교 국방과학학과 (석사과정)

<관심분야>

인공지능, 무기체계 획득, 산업안전공학

마정목(Jung-Mok Ma)

[정회원]



- 2002년 2월 : 육군사관학교 운영분석학과 (운영분석 학사)
- 2008년 8월 : 미국 펜실베이니아 주립대(PSU) (산업공학 석사)
- 2015년 5월 : 미국 일리노이대(UIUC) (산업공학 박사)
- 2015년 9월 ~ 현재 : 국방대학교 국방과학학과 부교수

<관심분야>

국방 모델링 및 데이터 분석학, 무기체계 획득관리