

포병 무기체계 분류를 위한 CNN 모델의 성능 비교 연구

이영균, 마정목*
국방대학교 국방과학학과

A Comparative Study on the Performance of CNN Models for Classification of Artillery Weapon Systems

Younggyoon Lee, Jungmok Ma*
Department of Defense Science, Korea National Defense University

요약 한반도의 지형적인 특징을 고려했을 때, 간접사격은 직접사격만큼 중요하며 아군의 피해를 최소화하면서 승리하기 위해서는 감시체계를 이용해 적의 포병을 먼저 찾고 격멸해야 한다. 전장에서 견인포, 자주포, 다련장 등 포병 무기체계를 구분하여 식별한다면 해당 무기체계를 운용하는 제대의 규모를 알 수 있다. 게다가 식별한 적 무기체계의 사거리 등을 고려해 아군이 유리한 전술을 수립해 전투를 수행할 수 있을 것이다. 이를 위해서 육안으로 무기체계를 식별하는 것이 아닌 자동으로 무기체계를 식별할 수 있는 체계가 도입되어야 한다. 본 연구는 이러한 목적을 바탕으로 진행되었으며 포병 무기체계 중 일부인 견인포, 자주포, 다련장의 이미지를 인터넷의 공개 이미지를 통해 약 900여장 수집하였고, 부족한 데이터 수를 보완하기 위해 이미지 증강기법을 사용하여 약 100배가량 증강시켰다. 이후 구글 기반의 사전 학습된 Xception, InceptionV3, MobileNetV2, DenseNet169, VGG16 그리고 VGG19라는 6가지 CNN 모델의 특징 추출기와 추가 분류기를 결합한 전이학습을 통해 무기체계 식별 성능을 비교하였다. 그 결과로 검증용 데이터셋의 정확도는 88.71% ~ 97.31%로 나타났으며, 그 중 가장 높은 성능을 가진 모델은 Xception 모델인 것으로 나타났다. 본 연구는 기 구축된 CNN모델과 전이학습을 이용해 포병 무기체계의 분류를 처음으로 시도한 연구이며 연구의 결과가 앞으로의 포병 무기체계 분류 및 식별에 관한 연구에 도움이 되기를 기대한다.

Abstract The topographical features of the Korean Peninsula mean that indirect fire is as important as direct fire. In order to win while minimizing casualties, enemy artillery must be located in advance using surveillance systems. Furthermore, if artillery weapon systems, such as multiple rocket launchers and towed and self-propelled artillery systems, in the battlefield are classified and identified, numbers of troops operating these weapon systems can be determined. In addition, knowledge of the types of enemy weapon systems would enable our troops to adopt more advantageous tactics. To this end, a system that can automatically identify weapon systems is required that does not depend on visualization. In this study, around 900 images of multiple rocket launchers and towed and self-propelled artillery systems were collected from publicly available images on the Internet and augmented by a factor of 100 using image augmentation techniques to compensate for lack of data. We then compared identification performances using transfer learning by combining feature extractors of six CNN models, namely, Google-based pre-trained Xception, InceptionV3, MobileNetV2, DenseNet169, VGG16, and VGG19, and additional classifiers. The accuracy of the test dataset ranged from 88.71% to 97.31%, and the Xception model performed best. This study represents a first attempt to classify artillery weapon systems using pre-trained CNN models and transfer learning, and its results are expected to aid future research on the classification and identification of artillery weapon systems.

Keywords : CNN, Transfer Learning, Types Of Artillery Weapons, Classification, Performance Result

본 논문은 국방대학교 연구과제로 수행되었음.

*Corresponding Author : Jungmok Ma(Korea National Defense Univ.)

email: jxm1023@gmail.com

Received November 7, 2022

Revised November 30, 2022

Accepted January 6, 2023

Published January 31, 2023

1. 서론

세계의 다양한 전술교리에서 강조하는 부분들과 전사들로 이뤄졌을 때 포병화력은 전쟁에서 핵심적인 역할을 차지해왔으며, 많은 전쟁에서 전투력 손실의 절반 이상이 포병의 화력으로 인해 발생한다고 해도 과언이 아니다. 분단국가인 대한민국은 전쟁이 끝난 지 70년이 되었지만 군사적 위협이 지속적으로 존재해 왔으며, 지형적으로는 64% 이상이 산악지형으로 이루어져 있고 도시화 또한 진행되고 있다는 특징을 가진다[1]. 이러한 특징을 지닌 한반도라는 전장에서 직접사격보다 간접사격의 중요성은 결코 낮지 않으며, 아군의 전투력 손실을 최소화하고 승리하기 위해서는 감시체계를 이용해 적의 포병을 먼저 찾고 격멸해야 한다. 특히 전장에서 견인포, 자주포, 다련장 등 포병 무기체계를 구분하여 식별하는 것은 해당 무기체계를 운용하는 제대의 규모를 알 수 있고, 식별한 적 무기체계의 사거리 등을 고려해 아군이 유리한 전술을 수립해 전투를 수행하는 결과로 나타날 수 있기에 중요하다. 그러나 군에서 활용되고 발전되어 왔던 감시체계는 대부분 육안에 의존해 운용되었으며, 실제로 먼 거리에서 무기체계를 육안으로 정확히 식별하는 것은 제한적이고 이를 감시할 수 있는 병력 또한 감소하고 있다[2].

다양한 민간 산업 분야에서는 영상 정보를 활용한 물체 식별, 탐지를 위해 인공지능 분야의 딥러닝 기술이 활용되고 있으며 이를 위한 데이터 확보도 비교적 용이하다. 하지만 다른 분야에 비해 국방 분야는 인터넷 활용과 물리적 서버 구축 제한, 접근성 문제, 정보 부족, 보안과 관련된 문제 등이 다량의 영상 데이터 등을 필요로 하는 딥러닝 기술을 적용하는데 걸림돌이 되고 있다[3]. 특히 한반도의 특수한 상황을 고려했을 때 전장에서 정확한 무기체계 식별이 중요하지만, 위와 같은 제한사항으로 인해 그 정확도가 검증된 연구 또한 그리 많지 않다.

따라서 본 논문에서는 인터넷을 통해 포병 무기체계 이미지 데이터를 수집하여 딥러닝 모형 중 CNN(Convolutional Neural Networks)의 여러 모델에 적용 후 정확도를 확인, 비교한다. 이미지 데이터는 포병 무기체계 중 견인포, 자주포, 다련장 무기체계로 총 3종이며, 국방 분야의 특성상 다량의 데이터 수집이 제한되기에 소규모의 이미지 데이터로 분석성능을 높일 수 있는 전이학습을 적용하였다.

본 연구는 2장에서 딥러닝 모형 중 CNN과 전이학습을 무기체계에 적용한 선행연구에 대해 소개하고, 실험

을 위해 수집한 이미지 데이터와 적용할 전이학습 모델에 대해 설명하였다. 3장에서는 전이학습 모델에 적용한 성능 결과를 확인하고 그 결과를 통해 모델들을 비교, 분석하였으며 마지막 4장에서는 결론, 발전사항 등을 제시하였다.

2. 본론

2.1 관련 연구

김태완 등(2020)은 공격작전 및 방어작전에서 중요하게 운용되고 짧은 시간에 식별해야 하는 헬기를 스스로 제안한 CNN 모형을 통해 공격형, 기동형 헬기로 분류하였다[2]. 황진용 등(2021)은 전차와 장갑차라는 지상 기동무기체계 영상 데이터와 기 구축된 5가지 딥러닝 모델을 바탕으로 전이학습 기반 앙상블 모델을 설계해 높은 정확도로 기동무기체계를 분류했다[3]. 이현기 등(2022)은 실물지뢰 GPR(Ground Penetrating Radar) 영상 데이터를 바탕으로 InceptionV3 신경망 모델을 통해 99.5%의 정확도를 보여 CNN을 활용한 지뢰탐지의 실효성을 제시하였다[5]. 박진영 등(2020)은 한국과 일본의 해경함정 영상 데이터에 CNN을 적용하여 국적을 식별하는 연구를 실시하였다[6]. 김종환 등(2021)은 실제 전장에서 직면할 10개의 한국, 북한군 무기체계 영상 데이터를 토대로 구글에서 개발된 딥러닝 모델에 전이학습을 진행해 피아식별 및 분류하는 연구를 실시하였다[7]. 김정환 등(2020)은 5개국에서 운용하는 수상전투함 영상 데이터를 토대로 딥러닝 중 YOLO v4 알고리즘을 이용해 탐지 및 국적 분류를 가능하도록 연구하였다[8]. 정미애 등(2020)은 CNN 모델을 비음향 탐지에 활용하여 각종 마스트를 운용중인 잠수함을 탐지하고 앙상블 모델로 성능을 향상시키는 방안을 제시하였다[9]. 최대욱 등(2019)은 선명한 이미지가 아닌 야간 및 저시정 해양환경의 선박 이미지를 CNN모델 중 VGG16을 활용해 효과적으로 분류하는 연구를 실시하였다[10]. 류제민 등(2022)은 기존 SAR ATR 연구에서 고려되지 않았던 초해상화를 적용한 이미지 분류 모델을 제시해 정확한 표적 정보를 얻는 결과를 도출하였다[11].

위와 같이 국방 분야에서도 다양한 딥러닝 기술과 전이학습, 초해상화 기법 등을 이용해 전차, 장갑차와 같은 지상의 기동무기체계, 지표면 및 지하의 실물 지뢰, 공중의 기동 및 공격형 헬기, 해상의 수상함, 잠수함 및 해경함정 등을 식별하고 분류하는 연구가 다양하

게 실시되었다. 하지만 CNN과 전이학습을 이용한 포병 무기체계의 식별, 분류와 관련한 연구는 진행되지 않았다.

2.2 관련 이론

2.2.1 합성곱 신경망(CNN)

CNN은 컴퓨터 비전에 뛰어난 성능을 가진 딥러닝 모형으로, 주로 컨볼루션층(Convolutional Layer), 풀링층(Pooling Layer) 등을 여러층으로 겹겹이 쌓은 구조이다.

합성곱은 두 가지 중요한 특성을 가지고 있는데, 첫 번째는 위치이동불변(Translation Invariant)으로 동일한 패턴이면 위치와 관계없이 동일하게 인식하는 특성을 가진다는 것이다. 두 번째는 계층적 패턴인식(Hierarchical Pattern Recognition)으로 입력층(Input Layer)과 출력층(Output Layer) 사이 다수의 층을 거치면 거칠수록 점차적으로 식별하려는 객체의 모습에 가까워지는 구조를 가지고 있다는 것이다[4].

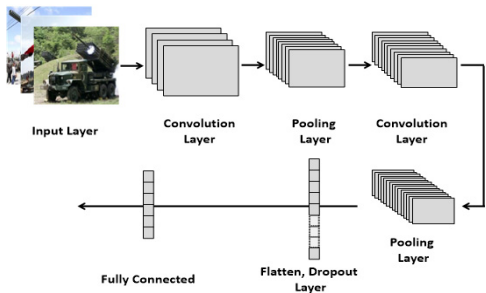


Fig. 1. A diagram of CNN model

Fig. 1은 CNN 모델 구조의 예시이다. 입력층에 입력된 이미지가 여러 겹으로 쌓여진 컨볼루션층, 풀링층을 통과하면서 특징이 추출되고 이미지 차원이 축소되며, 마지막 출력층에서 모델이 예측한 결과를 출력한다.

2.2.2 전이학습(Transfer Learning)

전이학습은 빅데이터를 통해 이미 학습된 딥러닝 모형을 이용해 소규모 자료의 분석성능을 높이고자 할 때 사용하는 학습방법이다[4]. 또한 보유하고 있는 소규모의 이미지 데이터와 기 구축된 CNN 모델이 관련이 없어도 높은 정확도가 나타날 수 있기에 본 연구에서는 전이학습을 적용하였다.




Fig. 2. The structure of Transfer learning on this study

Fig. 2는 본 연구에서 사용한 전이학습의 구조를 나타낸 것이다. 사전에 학습된 모델들의 추출기와 추가적인 분류기를 결합하였으며, 사전 학습된 모델의 종류는 Xception, InceptionV3, DenseNet169, MobileNetV2, VGG16, VGG19 총 6가지 모델이다[12-16]. 위 모델들은 구글의 “ImageNet”에서 주관한 이미지 분석과 관련한 대회에서 좋은 성능을 나타낸 모델들이며, 본 연구에서는 분류의 정확도, 층의 깊이 등을 고려하여 위 6가지 모델을 선정해 실험을 진행하였다.

Table 1. The structure of the additional classifier on this study

Index	Layer type	Input data form	Type
1	Input Layer	[[], 7, 7, 1280]	
2	Flatten Layer	[[], 62720]	Flatten
3	Dropout Layer	[[], 62720]	0.25
4	Dense Layer	[[], 512]	Relu
5	Dense Layer	[[], 256]	Relu
6	Dense Layer	[[], 64]	-
7	Dense Layer	[[], 3]	Softmax

본 연구에서는 위에 기술한 6개의 CNN 모델들의 사전 학습된 추출기와 Table 1의 추가 분류기의 결합을 통해 전이학습을 적용하였으며 위 Table 1은 추가 모델의 구조를 표로 정리하여 제시하였다.

2.3 데이터 수집

본 논문에서 연구대상인 포병 무기체계 3종 중 자주포는 견인포에서 발전된 개념이며 다련장과는 개념과 목적이 다르다. 자주포는 저렴한 포탄에 비해 화력이 우수하고 빠른 발사속도를 지니고 있으나 정확도가 비교적 낮으며, 상대적으로 하위 제대에서 운용하는 장비이다. 다련장은 비교적 장거리에 있는 핵심 표적에 대해 높은 정확도로 타격하지만, 포탄의 가격이 비싸며 재장전 및 재 보급 수요가 많다는 특징을 지닌다.



Fig. 3. Original data of artillery weapons

Fig. 3은 인터넷에서 수집한 견인포, 자주포, 다련장 이미지 데이터들이며 주로 견인포는 KM101 105mm와 KH-179 155mm를, 자주포는 K9과 K55를, 다련장은 K-136 구룡 다련장과 K-239 천무의 데이터를 수집하였다. 수집 간 웹 사이트에 견인포는 기종 또는 “Towed artillery”, 자주포는 “Self-propelled artillery”, 다련장은 “Multiple Rocket Launcher”라고 입력해 검색된 공개 이미지들을 수집하였다. 연구 목적상 북한 포병 무기체계의 영상자료를 수집하는 것이 적절하지만, 자료 획득의 한계성과 피아 무기체계의 외형적, 특징적 유사성을 고려하여 상대적으로 데이터 획득이 용이한 아군 무기체계를 수집하여 실험을 진행했다. Fig. 4는 인터넷에서 수집한 북한의 견인포, 자주포, 다련장 이미지 데이터들이다.



Fig. 4. Public image data of North Korea’s artillery weapons

Table 2와 같이 최종적으로 각 클래스 별 308장씩 총 924장을 수집하였으며 훈련 세트를 80%, 평가 세트를 20%로 분류하였다. 일반적으로 ImageNet 데이터셋 등은 수만 장 이상의 영상 데이터로 학습하기 때문에 수집한 데이터를 25도 범위 내 회전, 16도 범위 내 기울이기, $\pm 30\%$ 내 수평/수직 평행이동, $\pm 30\%$ 내 무작위 확대 및 축소 등을 통해 데이터를 약 100배 규모로 추가로 생성 및 증식하였다. Fig. 5는 데이터 증식을 통해 생성된 영상 데이터의 일부를 나타낸 것이다.




Fig. 5. Augmented data of artillery weapons

Table 2. Summary of dataset

Class	Training	Test	Total
Towed-artillery	246	62	308
Self-propelled artillery	246	62	308
Multiple Rocket Launcher	246	62	308
Total	738	186	924

3. 실험 방법 및 결과

3.1 실험 방법

2.2.2절에서 설명한 전이학습 실험을 위해 Windows 10 운영체제에서 구글 Tensorflow 2.9.2를 사용했으며 컴퓨터 자체의 NVIDIA GeForce RTX 2070 SUPER 외에 Google Colab Pro 환경에서 실험을 진행하였다.

Table 3. Hyper-parameters

Type	Input value
Input Image size	224x224
Batch size	6
Optimizer	Adam
Cost function	Categorical_crossentropy
Steps_per_epoch	123
Epoch	500
Validation steps	31
Learning rate	0.0002

모든 데이터의 입력 사이즈는 224x224이며 8:2의 비율로 학습, 검증용을 구분했고 배치 사이즈는 6으로, 학습 알고리즘은 Adam으로, 학습률은 0.0002로, 학습 횟수는 500으로 설정하여 실험을 진행하였다. 전이학습에 적용된 하이퍼파라미터는 이미지의 개수, 최종 분류 개수 등을 고려하였으며 세부사항은 Table 3에 제시하였다.

3.2 실험 결과

본 연구에서 포병 무기체계 3종에 대해 CNN 6개 모델의 추출기와 추가적인 분류기를 결합하는 전이학습을 통해 포병 무기체계를 식별한 결과는 다음과 같다. 각 CNN 모델별 정확도와 손실 정도가 차이가 있었으며 그 결과는 Fig. 6 및 Table 4에 제시하였다.

학습용 이미지 정확도는 연구에 사용된 모델 전부 94% 이상의 결과가 나왔으나 검증용 이미지의 정확도는 학습용 이미지의 정확도에 비해 조금 차이가 있었다. 가장 정확도가 낮은 모델은 VGG19로 88.71%의 정확도를 보였으며 가장 정확도가 높은 모델은 Xception으로 그 정확도는 97.31%이었다.

그래프에서 볼 수 있듯이 모델마다 조금씩 차이가 있지만 Epoch 횟수가 많아질수록 정확도는 올라가고 loss는 낮아졌으며 Epoch 횟수가 일정 횟수를 초과하면 그 상승과 하강 폭은 줄어드는 것을 확인할 수 있었다. 이러한 과정을 통해 Table 4의 결과를 얻었으며 본 연구에서 포병 무기체계 3종의 분류 정확도를 전이학습을 통해 검증용 이미지 기준으로 확인한 결과 Xception모델의 추출기와 결합한 전이학습 모델이 97.31%로 가장 우수한 성능을 보였으며 VGG19모델의 추출기와 결합한 전이학습 모델이 88.71%로 가장 낮은 성능을 보였다.

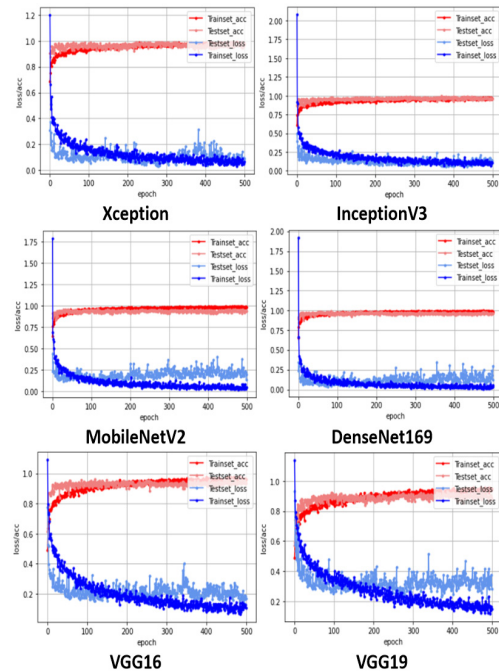


Fig. 6. Accuracy and Loss graphs of CNN models using transfer learning

Table 4. The result of CNN models using transfer learning

Criteria	Train Acc	Test Acc	Train loss	Test loss
Xception	97.56%	97.31%	0.0638	0.0883
InceptionV3	96.21%	95.70%	0.1050	0.1304
MobileNetV2	98.24%	93.55%	0.0512	0.1997
DenseNet169	98.51%	96.24%	0.0532	0.2932
VGG16	96.07%	93.55%	0.1082	0.1703
VGG19	94.72%	88.71%	0.1473	0.2840

4. 결론

본 연구는 전장에서 아군의 전투력 손실을 최소화하고 승리하기 위해 포병 무기체계의 선제적인 식별을 하기 위해 시작되었다. 그를 위해 육군의 다양한 무기체계 중 포병 무기체계인 견인포, 자주포, 다련장 3종의 이미지 데이터를 웹 검색을 통해 수집하였으며, 적은 데이터로도 높은 성능을 낼 수 있는 전이학습 적용을 위해 사전학습이 완료된 CNN 6가지 모델의 추출기와 추가 분류기를 결합하여 각 모델별 성능을 비교, 분석하였다. 그 결과로 6가지 모델은 검증용 데이터에 대해서 88.71% ~

97.31%의 정확도가 나타났으며, Xception 모델이 가장 우수한 성능을, VGG19 모델이 가장 저조한 성능을 보임을 확인했다.

본 연구의 제한사항 및 한계점으로는 더 다양한 곡사 화기, 포병 무기체계 등이 있으나 3개 종류로 한정되었다는 점, 획득할 수 있는 영상자료 수가 많지 않아 일정 부분 획득하고 이미지 증강기법으로 변형시켜 확보했다는 점, 전장 상황을 고려했을 때 무기체계 운용 간 악기상에서 운용할 수 있는 상황도 고려해야 하지만 이미지 데이터가 무기체계의 악기상 하 운용 부분을 반영하지 않았다는 점 등이 있겠다. 또한 연구의 목적은 적의 무기체계를 식별하는 것이기 때문에 북한의 포병 무기체계 영상자료를 사용해야 더욱 효과적이지만 자료 획득의 한계성으로 인해 아군 무기체계 영상자료를 사용했다는 것도 한계점이라고 할 수 있다. 그렇지만 지금까지 포병 무기체계 분류에 대해서는 연구가 진행되지 않았기에 전이 학습을 통한 본 연구는 의의가 있다고 할 수 있다.

마지막으로 현 연구에서는 단순 분류만 실시했지만 앞으로 포병 무기체계 분야에서도 피아 무기체계 식별, 국적 식별, 무기체계의 세부 종류 분류 등의 연구까지 확장되고 그러한 부분이 감시체계와 결합하여 운용된다면 전장에서 유리한 고지를 점할 수 있을 것이다.

References

- [1] <https://namu.wiki/w/%ED%95%9C%EB%B0%98%EB%8F%84>
- [2] T. W. Kim, H. S. Moon, J. H. Kim, "The Study on CNN based Helicopter Type Classification Model", *Institute of Control, Robotics and Systems*, Vol.26, No.6, pp.479-486, Jun, 2020.
DOI: <https://dx.doi.org/10.5302/J.ICROS.2020.20.0017>
- [3] J. Y. Hwang, B. A. Choi, J. H. Lee, J. H. Bae, "A Study on Transfer Learning-based Ensemble Model for Classification of Maneuver Weapon System", *Korean Institute Of Information Technology*, Vol.19, No.12, pp.1-10, Dec, 2021.
DOI: <https://dx.doi.org/10.14801/ikj.2021.19.12.1>
- [4] Y. S. Park, Deep Learning using Tensorflow Keras, p.616, Free Academy Publisher, 2021, pp.152-163
- [5] H. G. Lee, J. M. Ma, "A Study on Mine Detection in GPR Images Using CNN", *The Korea Academia-Industrial cooperation Society*, Vol.23, No.6, pp.82-88, Jun, 2022.
DOI: <https://dx.doi.org/10.5762/KAIS.2022.23.6.82>
- [6] J. Y. Park, J. H. Kim, H. S. Moon, "A Study on Expert System for Nationality Classification of Coast Guard Ship using Convolution Neural Network", *The Research Institute of Future Industry*, Vol.44, No.1, pp.45-60, May 2020.
DOI: <https://dx.doi.org/10.22915/rifi.2020.44.1.003>
- [7] J. H. Kim, T. W. Kim, S. C. Kim, J. Y. Ryu, "Transfer Learning based Intelligent Target Detection and Identification Model Analysis for Unmanned Recon Vehicle", *Military Operations Research Society Of Korea*, Vol.47, No.2, pp.26-35, Dec, 2021.
- [8] J. H. Kim, H. S. Moon, "A model development for object detection and classification at sea using modified YOLO v4", *Military Operations Research Society Of Korea*, Vol.47, No.2, pp.13-25, Dec, 2021.
- [9] M. A. Jeong, J. M. Ma, "A Study on the Improvement of Submarine Detection Based on Mast Images Using An Ensemble Model of Convolutional Neural Networks", *Journal of the Korea Institute of Military Science and Technology*, Vol.23, No.2, pp.115-124, Apr, 2020.
DOI: <https://dx.doi.org/10.9766/kimst.2020.23.2.115>
- [10] D. W. Choi, J. M. Ma, "A Study on the Improvement of Ship Classification and classification on Artificial Neural Network Considering Night and Low Visibility Marine Environment", *Korean Journal of Computational Design and Engineering*, Vol.24, No.3, pp.320-328, Sep, 2019.
DOI: <https://dx.doi.org/10.7315/CDE.2019.320>
- [11] J. M. Ryu, J. M. Ma, "Automatic Target Recognition of Military SAR Images Using Super-Resolution based Convolutional Neural Network", *Journal of Institute of Control, Robotics and Systems*, Vol.28, No.1, pp.22-27, Jan, 2022.
DOI: <https://dx.doi.org/10.5302/J.ICROS.2022.21.0178>
- [12] F. Chollet, "Xception: Deep Learning with Depthwise Separable Convolutions", *2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, pp.1800-1807, 2017.
DOI: <https://dx.doi.org/10.1109/CVPR.2017.195>
- [13] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, Z. Wojna, "Rethinking the Inception Architecture for Computer Vision", *2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, pp.2818-2826, 2016.
DOI: <https://dx.doi.org/10.1109/CVPR.2016.308>
- [14] G. Huang, Z. Liu, L. van der Maaten, K. Q. Weinberger, "Densely Connected Convolutional Networks", *2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, pp.2261-2269, 2017.
DOI: <https://dx.doi.org/10.1109/CVPR.2017.243>
- [15] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, L. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks", *The IEEE Conference on CVPR*, Salt Lake City, UT, USA, pp.4510-4520, 2018.
DOI: <https://dx.doi.org/10.1109/CVPR.2018.00474>
- [16] K. Simonyan, A. Zisserman, "Very Deep Convolutional Networks for Large-scale Image Recognition", *ICLR*, pp.1-14, Apr, 2015.

이 영 균(Younggyoon Lee)

[준회원]



- 2013년 2월 : 육군사관학교 응용 물리학과 (응용물리 학사)
- 2021년 1월 ~ 현재 : 국방대학교 국방과학학과 석사과정

<관심분야>

영상분석, 국방 모델링, 무기체계 획득관리

마 정 목(Jungmok Ma)

[정회원]



- 2002년 2월 : 육군사관학교 운영 분석학과 (운영분석 학사)
- 2008년 8월 : 미국 펜실베니아 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