

레터논문 (Letter Paper)

방송공학회논문지 제27권 제6호, 2022년 11월 (JBE Vol.27, No.6, November 2022)

<https://doi.org/10.5909/JBE.2022.27.6.936>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

무장 선택을 위한 딥러닝 기반의 비행체 식별 기법 연구

차 은 영^{a)}, 김 정 창^{a)†}

A Study on Deep Learning based Aerial Vehicle Classification for Armament Selection

Eunyoung Cha^{a)} and Jeongchang Kim^{a)†}

요 약

최근 공중 전투체계 기술들이 발전함에 따라 대공방어 시스템의 발전이 요구되고 있다. 대공 방어 시스템의 운용개념에 있어, 표적에 적합한 무장을 선택하는 것은 제한된 대공 전력을 사용하여 위협체에 대해 효율적으로 대응한다는 측면에서 체계에 요구되는 능력 중 하나이다. 비행 위협체의 식별에 있어 많은 부분이 운용자의 육안 식별에 의존하는데 고속으로 기동하고 원거리에 위치한 비행체를 육안으로 판별하는 것은 많은 한계가 있다. 뿐만 아니라, 현대 전장에서 무인화 및 지능화된 무기체계의 수요가 증가함에 따라 운용자의 육안 식별 대신 체계가 자동으로 비행체를 식별하고 분류하는 기술의 개발이 필수적이다. 영상자료를 수집해 딥러닝 기반의 모델을 이용하여 무기체계를 식별한 사례로는 전차와 함정 등이 있지만 비행체의 식별에 대한 연구는 아직 많이 부족한 상황이다. 따라서 본 논문에서는 합성곱 신경망 모델을 이용하여 전투기, 헬기, 드론을 분류하는 모델을 제시하고 제시하는 모델의 성능을 분석한다. 본 논문에서 제시하는 모델은 시험세트에 대해 95% 이상의 정확도를 보이고, precision 0.9579, recall 0.9558, F1-score 0.9568의 값을 나타내는 것을 확인할 수 있다.

Abstract

As air combat system technologies developed in recent years, the development of air defense systems is required. In the operating concept of the anti-aircraft defense system, selecting an appropriate armament for the target is one of the system's capabilities in efficiently responding to threats using limited anti-aircraft power. Much of the flying threat identification relies on the operator's visual identification. However, there are many limitations in visually discriminating a flying object maneuvering high speed from a distance. In addition, as the demand for unmanned and intelligent weapon systems on the modern battlefield increases, it is essential to develop a technology that automatically identifies and classifies the aircraft instead of the operator's visual identification. Although some examples of weapon system identification with deep learning-based models by collecting video data for tanks and warships have been presented, aerial vehicle identification is still lacking. Therefore, in this paper, we present a model for classifying fighters, helicopters, and drones using a convolutional neural network model and analyze the performance of the presented model.

Keyword : Aerial vehicle, Air defense, Armament selection, CNN, Deep learning

I. 서론

최근 무인기나 전투기와 같이 공중 전투 체계 기술들이 급격하게 발전함에 따라 대공 방어 체계의 중요성이 부각되고 있다. 대공 방어에 있어 교전 승인이 이루어지면, 표적에 적합한 무장을 선택해야 하는데 이는 위협도가 상대적으로 낮은 대공 위협체에 유도 무기 등을 사용하는 것은 비효율적인 결과를 초래하기 때문이다. 위협체의 식별에 있어 많은 경우에 사용자의 육안에 의존한다. 그러나 먼 거리에 위치하고 고속으로 기동하는 무기체계를 육안으로 판별하는 것에는 많은 제약이 따른다. 따라서, 체계 내의 시스템이 스스로 위협체를 탐지하고 식별하는 기술의 발전이 요구되고 있다. 딥러닝(deep learning) 모델을 이용한 무기체계의 분류는 주로 전차 등의 지상장비^[2]에 대한 연구가 이루어졌다. 그러나 비행 표적의 자동 식별에 대한 연구는 부족한 실정이다. 따라서 본 논문에서는 합성곱 신경망 모델을 이용하여 전투기, 헬기, 드론을 분류하고 표적에 적절한 무장을 선택하는 방법에 대해 연구한다.

II. 본론

1. 학습데이터

본 논문에서는 그림 1과 같은 형태를 가지는 드론, 헬기, 전투기 세계의 클래스로 영상데이터를 수집하고 라벨링(labeling)을 통하여 학습을 위한 데이터를 구성하였다. 영상 데이터의 수집은 Kaggle의 공개 이미지^[3]목록에서 드론, 헬기, 전투기에 해당하는 이미지를 검색하여 사용하였다.



그림 1. 학습에 사용된 드론(왼쪽), 헬기(가운데), 전투기(오른쪽) 이미지 예시
Fig. 1. Examples of drone, helicopter, fighter data

수집된 이미지는 전투기, 헬기, 드론 데이터의 개수를 각 1000장씩으로 구성하였으며 각각의 클래스별로 850장씩 전체 2550장을 훈련 및 검증에 사용하였고 나머지 150장씩을 시험용으로 사용하였다. 부족한 데이터의 수를 극복하기 위해 데이터 증식(data augmentation) 과정을 수행하였다. 데이터 증식 방법으로 좌/우 30도로 제한한 영상데이터의 회전, 15%의 확대/축소, 20%의 좌우/상하 이동, 30%좌우/상하 반전을 사용하였고 그림 2는 증강된 데이터들 중 일부를 표시하였다. 이를 통해 적은 수의 데이터 셋에서도 각각의 비행체를 구분할 수 있는 모델을 훈련할 수 있도록 하였다.




그림 2. 데이터 증강을 적용한 드론(왼쪽), 헬기(가운데), 전투기(오른쪽) 데이터
Fig. 2. Examples of augmented drone, helicopter, fighter data

2. 사전 학습모델

본 논문에서는 이미지나 영상을 활용한 딥러닝 연구에 대표적으로 사용되는 그림 3과 같은 구조의 합성곱 신경망(Convolutional Neural Network, CNN)을 사용한다^[4].

CNN 기반 딥러닝 기술에서 데이터 크기와 시간의 제한을 극복하기 위해 다양한 연구들이 진행되고 있는데, 전이 학습은 적은 데이터의 양으로도 빠른 학습속도와 높은 정확도를 가질 수 있는 학습방법이다^[5]. 전이학습은 사전에

a) 한국해양대학교 전자통신공학과 해양인공지능융합전공(Interdisciplinary Major of Maritime AI Convergence, Department of Electronics and Communications Engineering, Korea Maritime and Ocean University)

‡ Corresponding Author : 김정창(Jeongchang Kim)

E-mail: jchkim@kmou.ac.kr

Tel: +82-51-410-4315

ORCID:https://orcid.org/0000-0002-8612-9360

· Manuscript August 31, 2022; Revised November 24, 2022; Accepted November 24, 2022.




그림 3. 사용된 CNN 모델 구조
Fig. 3. An architecture of Convolutional Neural Network

학습 완료된 모델의 가중치를 사용하고 본 논문에서는 “ImageNet”을 기반으로 한 사전학습 모델을 사용하였다. 최종 사전학습 모델을 결정하기 위해 ResNet50, VGG16, MobileNetV2 세 모델을 후보로 지정하여 epoch=1에 대한 학습 모델 성능을 살펴보고 각 모델의 성능은 표 1과 같다.

표 1. ResNet50, VGG16, MobileNetV2의 사전학습 모델 성능
Table 1. Pre-trained model performance on ResNet50, VGG16, MobileNetV2

Model	ResNet50	VGG16	MobileNetV2
Accuracy	0.62	0.93	0.95

ImageNet을 기반으로 한 사전학습 모델 중 본 논문에서는 모델의 경량성과 학습 속도를 고려하여 MobileNetV2를 사용하였다. MobileNetV2는 depthwise convolution을 통해 연산량을 줄인 모델로서 경량이지만 효율적이고 높은 성능을 가지는 모델이다. MobileNetV2에 사전학습 가중치를 이용하고 사전 학습 구조에 완전 연결 계층을 합하여 드론, 헬리콥터, 전투기 학습데이터에 대해 새롭게 학습한다.

III. 전산실험 및 결과

1. 학습모델

훈련 세트(training set) 2295개, 검증 세트(validation set)

표 2. 학습 모델에 사용한 파라미터
Table 2. Parameters of training model

Input size	Batch size	Optimizer	Learning rate	Epoch	Activation function	Classification
224x224	32	Adam	0.001	50	ReLU	softmax

255개를 구성하여 데이터 증식을 수행하였고 시험 세트 (test set) 450개를 구성하였다. 학습 파라미터를 표 2와 같이 옵티마이저(optimizer)는 아담(Adam), 학습률(learning rate)은 0.001, 배치 사이즈(batch size)는 32를 적용하였다. 전이학습에 사용된 사전학습 모델로는 MobileNetV2를 사용하였고 옵티마이저(optimizer)로는 아담을 사용하였다. MobileNetV2의 구조를 동결시켜 가중치를 차용하고, 완전 연결 계층을 추가하여 가중치를 학습하도록 하였는데, 이때 분류기의 활성화함수로는 ReLU, 최종 분류층으로는 softmax를 사용하였다.

2. 분류 성능 결과

본 논문에서 모델의 성능을 평가하기 위해서 학습된 모델의 오차행렬(confusion matrix)을 구하였고 그 결과는 표 3과 같다. TP(true positive), TN(true negative), FP(false positive), FN(false negative), 값을 이용해 분류 모델의 평가 척도인 Accuracy, Precision, Recall, F1-score의 값을 도출하여 표 4에 제시하였다. 이때, TP값은 입력 클래스를 올바르게 예측한 값으로 오차행렬에서 대각선 값을 의미하고 TN값은 해당 클래스가 아닌 입력 클래스에 대해 해당 클래스가 아니라고 예측하는 것을 의미한다. 예를 들어 Drone 클래스에서는 Drone 클래스의 행과 열을 제외한 나머지 값들이 TN 값을 의미한다. FP는 해당 클래스가 아닌 입력 클래스를 해

당 클래스로 잘못 예측한 것으로서, 예를 들어 Drone이 아닌 클래스에 대해 Drone으로 예측한 것을 의미하며 오차행렬의 Drone열에서 Drone을 제외한 나머지가 FP값에 해당한다. FN은 각 입력 클래스에 대해 해당 입력 클래스를 제외한 나머지로 예측한 것으로서, 예를 들어 Drone 클래스에 대해 Drone이 아닌 나머지로 예측한 값을 의미한다.

표 3. 분류 모델의 비행체 분류 오차행렬
 Table 3. Classification confusion matrix of the classification model

Label/Prediction	Drone	Helicopter	Jet
Drone	0.9262	0.0470	0.0268
Helicopter	0.0	1.0	0.0
Jet	0.0065	0.0523	0.9412

표 4. 분류 모델의 비행체 분류 결과
 Table 4. Aerial vehicle classification result of classification model

Accuracy	0.9556
Precision	0.9579
Recall	0.9558
F1-score	0.9568

이때, 각각의 클래스에 대한 Accuracy, Precision, Recall, F1-score은 수식 (1)-(4)^[6]에 의해 구해진다.

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3)$$

$$\text{F1-score} = 2 \times \frac{\text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (4)$$

표 4는 각각의 클래스에 대해 구한 Accuracy, Precision, Recall, F1-score 값을 평균한 결과이다. 표 4에서 볼 수 있듯이, 입력 데이터에 대해 판단 내린 클래스 중 실제로 정답 클래스로 판단한 경우인 Precision은 0.9579을 나타내고 입

력 클래스에 대해 해당하는 클래스로 판단한 경우인 Recall 값은 0.9558로 나타난다. Precision과 Recall값의 조화평균으로 계산되는 F1-score값은 0.9568로 F1-score를 통해 판단하였을 때, 모델은 높은 성능을 보인다고 판단할 수 있다.

IV. 결 론

본 논문에서는 공중 전투 체계 중 전투기, 헬기, 드론의 영상자료를 기초로 합성곱 신경망을 적용하여 각 무기체계를 분류할 수 있는 딥러닝 모델을 제시하였고, 그 모형에 대한 성능을 평가하였다. 제시하는 모델은 실험 결과를 통해 비행 표적의 식별에 있어 인공지능의 활용 가능성을 확인했다. 실제 무기 체계 운용 중에 딥러닝 모델을 적용하기 위해서는 주/야간과 외란이 발생하는 상황에서 모두 작동할 수 있어야 한다. 따라서 추후에는 실제 체계 운용 중에 발생할 수 있는 다양한 환경에서 수집한 비행체 영상과 적외선 영상을 추가로 활용하여 실전에서 활용이 가능한 수준의 비행체 식별을 연구할 예정이다.

참 고 문 헌 (References)

- [1] J.Hwang, D. Han, J. Park, "A Study on the Operating Concept and Combat Process of New Generation Air defense System", Proceeding of Conference Korea Institute of Military Science and Technology, Jeju, Korea, pp.1699-1700, 2020.
- [2] S.Lim, D.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>
- [3] <https://www.kaggle.com/datasets/>. [accessed: August. 22, 2022]
- [4] E. Lee, "Basic and Applied Research of CNN and RNN," Broadcasting and Media Magazine, Vol. 22, No. 1, pp.87-95, 2017.
- [5] D. Lee, G. Park. "Analysis of Transfer Learning Effect for Automatic Dog Breed Classification" Journal of Broadcast Engineering, Vol. 27, No. 1, pp.133-145, 2022.
- [6] J. Lee, S. Yoo, S. Shin, D. Kang, S. Lee, J. Lee, "Fault Diagnosis of Bearings Using Machine Learning Algorithm", Journal of Advanced Marine Engineering and Technology, Vol. 43, No. 6, pp.455-462, 2019. doi: <https://doi.org/10.5916/jkosme.2019.43.6.455>