

http://dx.doi.org/10.17703/JCCT.2024.10.4.639

JCCT 2024-7-74

드론 식별 시스템을 위한 합성곱 신경망 기반 이미지 분류 모델 성능 비교

Performance Comparison of CNN-Based Image Classification Models for Drone Identification System

김영완*, 조대균**, 박건우***

YeongWan Kim*, DaeKyun Cho**, GunWoo Park***

요약 최근 전장에서의 드론 활용이 정찰뿐만 아니라 화력 지원까지 확장됨에 따라, 드론을 조기에 자동으로 식별하는 기술의 중요성이 더욱 증가하고 있다. 본 연구에서는 드론과 크기 및 외형이 유사한 다른 공중 표적들인 새와 풍선을 구분할 수 있는 효과적인 이미지 분류 모델을 확인하기 위해, 인터넷에서 수집한 3,600장의 이미지 데이터셋을 사용하고, 세 가지 사전 학습된 합성곱 신경망 모델(VGG16, ResNet50, InceptionV3)의 특징 추출기능과 추가 분류기를 결합한 전이 학습 접근 방식을 채택하였다. 즉, 가장 우수한 모델을 확인하기 위해 세 가지 사전 학습된 모델(VGG16, ResNet50, InceptionV3)의 성능을 비교 분석하였으며, 실험 결과 InceptionV3 모델이 99.66%의 최고 정확도를 나타냄을 확인하였다. 본 연구는 기존의 합성곱 신경망 모델과 전이 학습을 활용하여 드론을 식별하는 새로운 시도로써, 드론 식별 기술의 발전에 크게 기여 할 것으로 기대된다.

주요어 : 드론, 전이 학습, 이미지 분류, 합성곱 신경망, 공중표적

Abstract Recent developments in the use of drones on battlefields, extending beyond reconnaissance to firepower support, have greatly increased the importance of technologies for early automatic drone identification. In this study, to identify an effective image classification model that can distinguish drones from other aerial targets of similar size and appearance, such as birds and balloons, we utilized a dataset of 3,600 images collected from the internet. We adopted a transfer learning approach that combines the feature extraction capabilities of three pre-trained convolutional neural network models (VGG16, ResNet50, InceptionV3) with an additional classifier. Specifically, we conducted a comparative analysis of the performance of these three pre-trained models to determine the most effective one. The results showed that the InceptionV3 model achieved the highest accuracy at 99.66%. This research represents a new endeavor in utilizing existing convolutional neural network models and transfer learning for drone identification, which is expected to make a significant contribution to the advancement of drone identification technologies.

Key words : Drones, Transfer learning, Image classification, Convolutional Neural Networks, Aerial targets

*정회원, 해군 제2함대사령부 (제1저자)
**정회원, 국군방첩사령부 국방보안연구소 (공동저자)
***정회원, 대전대학교 컴퓨터공학과 교수 (교신저자)
접수일: 2024년 4월 22일, 수정완료일: 2024년 5월 23일
게재확정일: 2024년 6월 15일

Received: April 22, 2024 / Revised: May 23, 2024
Accepted: June 15, 2024
***Corresponding Author: goddkp1@google.com

I. 서론

드론은 4차 산업혁명의 여러 신기술 중 하나로써, 그 유용성을 널리 인정받아 현재 재난구조, 농업, 물류 수송, 감시 및 보안 등 다양한 분야에서 핵심 기술로 자리매김하고 있다. 특히 군사용 무기로써 드론은 매우 큰 활용 가치를 지니고 있다[1].

최근에는 초소형화된 드론에 AI 기술을 접목하여, 기존의 정찰 역할을 넘어 핵심표적에 대해 타격 또는 자폭을 통한 공격 능력을 갖춰 화력 기능을 수행할 수 있게 되었다[2, 3]. 이러한 기능 확장으로 인해 드론을 활용한 적의 공격이 아군의 핵심 목표물을 타격할 경우, 전장에서 아군 피해가 상당함은 물론 승리도 보장할 수 없게 될 것이다. 따라서, 아군의 피해를 최소화하고 승리를 보장하기 위해서는 기존 감시체계를 보다 더 적극적으로 활용하여 적의 드론을 조기에 식별하고 방어하는 전략이 필수적이다.

현재 군에서 활용하는 드론 감시체계는 대부분 레이더나 운용자의 육안에 의존하고 있으나, 이는 공중으로 이동하는 소형 물체를 식별하는 데 큰 제약이 따르며, 감시를 위한 운용 인력 감소 문제도 동시에 직면하고 있다. 이에 따라, 자동으로 드론을 탐지하고 식별할 수 있는 전문 드론 탐지 시스템의 개발이 절실하게 요구된다.

한편, 민간 산업에서는 물체식별과 탐지를 위해 AI 기술 중 하나인 딥러닝이 널리 사용되고 있다. 국방 분야에서도 합성곱 신경망 기반의 이미지 분류 모델을 이용한 무기체계 식별 연구가 진행되었으나, 대부분 전차나 함정과 같은 무기에 초점을 맞추었고 드론 식별에

관한 연구는 상대적으로 부족했다. 본 연구는 이러한 배경을 바탕으로, 드론 식별에 적합한 다양한 이미지 분류 모델들의 성능을 비교하고 분석하였다.

본 연구의 구성은 다음과 같다: 2장에서는 국방 분야에서 이미지 분류 모델을 활용한 선행연구를 소개하고, 실험에 사용할 데이터와 모델을 상세히 설명하였다. 3장에서는 실험을 통해 얻은 이미지 분류 모델의 성능 결과를 확인하고, 이를 바탕으로 모델들을 비교 분석하였다. 마지막으로, 4장에서는 연구 결과를 종합하고 드론 식별 기술의 향후 발전 가능성과 방향을 제시하였다.

II. 본론

1. 관련 연구

국방 분야에서 CNN(Convolutional Neural Network) 기반 이미지 분류 모델을 이용한 무기체계 식별에 관한 이전 연구를 정리하면 아래 표 1과 같다.

[4]는 소규모의 지상 기동 무기체계 이미지를 수집하고 전이 학습 기반 앙상블 모델을 적용한 합성곱 신경망을 통해 보다 높은 정확도로 전차와 장갑차를 분류하였다. [5]에서는 영상 장비를 통해 획득한 영상 정보에 CNN을 사용하여 한국과 일본의 해경 함정을 식별하는 전문가시스템에 관해 연구하였다. [6]은 합성곱 신경망을 활용하여 마스트를 운용 중인 잠수함을 탐지하고 더욱 정확한 예측을 위해 앙상블 모델을 적용하는 방안을 제시하였다. [7]에서는 전장에서 유리한 전술을 수립하기 위해 다양한 합성곱 신경망 알고리즘을 활용하여 견인포, 자주포, 다련장 등의 포병 무기체계를 분류하고

표 1. CNN 기반 이미지 분류 모델을 활용한 무기체계 식별에 관한 연구

Table 1. Studies on weapon system identification using a image classification models based on CNN

Division	Studies	Identified weapon system	Used Model
1	A study on transfer learning-based ensemble model for classification maneuver weapon system[4]	Tanks and armored vehicles	VGG19, ResNet50, DensNet121, InceptionV3, MobileNetV2
2	A study on expert system for nationality classification of coast guard ship[5]	Coast guard ship	InceptionV3
3	A study on the improvement of submarine detection based on mast images using an ensemble mdoel of convolutional neural networks[6]	Submarine	VGG16, ResNet50, InceptionV3, its own model
4	A comparative study on the performance of CNN models for classification of artillery weapon systems[7]	Artillery Weapons	VGG16, VGG19, DenseNet169, InceptionV3, MobileNetV2, Xception,

이에 대한 성능을 비교하였다.

위와 같이 국방 분야에서 딥러닝의 대표적 기술인 합성곱 신경망 기반 이미지 분류 모델을 활용하여 지상의 전차, 견인포 및 해상의 함정 등 다양한 무기체계의 식별과 분류를 위한 연구가 진행되었다. 그러나 최근 전장에서 핵심적인 역할을 하는 드론 식별에 관한 연구는 상대적으로 부족한 실정이다.

2. 관련 이론

1) Convolutional Neural Network

합성곱 신경망은 인공지능에서 음성인식 및 이미지 처리에 최적화된 딥러닝 기법으로 1989년 Yann LeCun에 의해 처음 소개된 이후 지금까지 많은 연구가 진행되었다. [8]. 합성곱 신경망은 그림 1과 같이 피쳐 러닝 계층과 분류 계층으로 구분되는데 피쳐 러닝 계층은 다시 컨볼루션 레이어와 풀링 레이어로, 분류 계층은 완전 연결 레이어와 소프트 맥스 레이어로 나뉜다.

컨볼루션 레이어는 합성곱 연산을 통하여 이미지의 특징을 식별하고, 풀링 레이어는 컨볼루션 레이어가 생성한 특징맵의 크기를 줄여 연산량을 감소시킨다. 이후 완전 연결 레이어를 거치면서 추출된 특징들이 모두 뉴런으로 연결되고 최종적으로 소프트 맥스 레이어에서 클래스 분류 확률값을 출력한다.




그림 1. 합성곱 신경망의 구조
 Figure 1. An architecture of CNN

2) 전이 학습(Transfer learning)

합성곱 신경망은 다수의 은닉층을 포함하고 있어 모델의 복잡도가 높고 모델이 요구하는 수준의 성능을 구현하기 위해서는 충분한 양의 데이터를 학습시켜야 한다. 이는 많은 시간과 컴퓨터 자원을 필요로 하며 만약 데이터가 부족할 경우 모델에 과적합이 발생하여 새로운 데이터셋에서는 모델이 성능을 올바르게 발휘하기 어렵다. 특히 인터넷에서 직접 수집한 이미지 데이터셋을 활용하기 때문에 모델 학습을 위한 충분한 양의 데

이터를 확보하기에 매우 제한적이다.

따라서, 본 연구에서는 효율적으로 시간과 필요 자원을 활용하기 위해 상대적으로 적은 데이터셋을 이용하여 높은 정확도를 나타낼 수 있는 전이 학습을 모델에 적용한다. 전이 학습을 위해 ImageNet의 풍부한 데이터셋을 이용하여 사전에 학습된 모델들의 추출기에 새로운 분류기를 결합하였다. 사전 학습된 모델의 종류는 Tensorflow에서 제공하는 VGG16, ResNet50, InceptionV3 총 3가지 모델을 활용한다.

VGG16의 3x3 크기의 작은 필터를 통해 네트워크를 충분히 깊게 하여 모델이 효과적으로 이미지 특징을 학습하는 특징이 있다. 또한 균일한 구조와 간결한 디자인으로 인해 이해와 구현이 쉬운 장점이 있어 영상 분류 및 객체 감지에 널리 사용되고 있다[9].

ResNet50은 2015년 Microsoft research에서 발표한 모델로 레이어가 깊어질수록 기울기가 소멸되는 문제를 잔여 학습을 통해 해결하였다. 이를 통해 보다 더 깊은 신경망을 구성하여 높은 정확도를 달성하였다[10].

InceptionV3는 다양한 크기의 커널을 동시에 사용하는 Inception 모듈을 도입하여 이미지의 다양한 특징을 효과적으로 추출하는 특징이 있다. 이를 통해 네트워크가 다양한 크기의 패턴을 처리할 수 있게 하여 객체의 크기나 모양이 다양한 경우에 효과적이다[11].

본 연구의 실험에서는 3가지의 합성곱 신경망 모델들의 사전 학습된 추출기와 아래 표 2의 새로운 분류기 결합을 통해 전이 학습을 적용하였다.

표 2. 새로운 분류기의 구조
 Table 2. The structure of the additional classifier

Layer type	Input data form	Type
Input	[(none, 7, 7, 2048)]	-
Flatten	[(none, 2048)]	Global Average Pooling
Dropout	[(none, 2048)]	0.5
dense	[(none, 512)]	Relu
dense	[(none, 256)]	Relu
dense	[(none, 128)]	-
dense	[(none, 3)]	Softmax

IV. 실험 및 분석

1. 학습데이터

데이터셋은 그림 2와 같이 드론 및 드론과 유사한 크기의 공중물체인 풍선, 새의 이미지로 구성하였고 Kaggle[12]에서 공개한 이미지 리스트에서 드론, 새, 풍

선에 해당하는 이미지를 검색하여 활용하였다.




그림 2. 학습에 사용된 드론(A), 풍선(B), 새(C) 이미지 예시
Figure 2. Examples of collected dataset

표 3과 같이 최종적으로 클래스별 1,200장씩 총 3,600장을 수집하였으며, 학습 데이터셋은 960장, 테스트 데이터셋은 240장으로 분류하였다.

표 3. 데이터셋 정리
Table 3. Summary of dataset

Class	Training	Test	Total
Drone	960	240	1200
Balloon	960	240	1200
Bird	960	240	1200

수집한 데이터셋은 기존의 합성곱 신경망 기반 모델이 사용하는 ImageNet과 같은 대규모 데이터셋에 비해 상대적으로 작다. 따라서 데이터의 다양성을 향상시키기 위해 이미지를 추가로 확장하였다. 이를 위해 10도 회전, 이미지의 수직 및 수평 이동, 그리고 확대 및 축소와 같은 변형을 적용하였다.

2. 실험방법

전이 학습 모델을 이용하여 수집한 데이터셋으로 모델 간의 성능을 비교 분석하였다. 표 4는 실험을 수행한 시스템 환경을 나타내며, 실험에는 구글의 Colab 플랫폼을 활용하였다.

표 4. 실험환경
Table 4. Environment of experiment

Environment	Details
CPU	Intel Pentium(R) CPU 4415U@ 2.3GHz
RAM	4GB
SSD	102GB
OS	Windows 10 Home
Deep learning framework	Keras 2.8.0
Language	Python 3.7.5

데이터셋의 입력 크기는 224×224이며, 데이터를 8:2 비율로 학습용과 평가용으로 나누었다. 배치 크기 (Batch Size)는 32, 옵티마이저(Optimizer)는 아담 (Adam)을 사용하였고, 에포크(epoch) 수는 100, 학습률 (Learning Rate)은 0.5로 설정하여 실험을 진행하였다. 표 5는 전이 학습 모델에 적용된 하이퍼파라미터 (Hyper Parameters)의 세부 사항을 나타낸다.

표 5. 전이 학습 모델에 적용된 Hyper parameters
Table 5. Hyper parameters applied to transfer learning models

Type	Input value
Input image size	224×224
Batch size	32
Optimizer	Adam
Cost function	Categorical crossentropy
Epoch	100
Learning rate	0.5

3. 실험 결과 및 분석

드론 및 유사한 공중물체의 식별 및 분류를 위해 세 가지 주요 이미지 분류 모델-VGG16, InceptionV3, ResNet50-의 성능을 체계적으로 평가하였으며, 평가 척도로는 모델의 정확도(Accuracy)를 적용하였다. 드론, 풍선과 새를 대상으로 한 실험에서 세 모델의 특징 추출기와 추가 분류기를 결합한 전이 학습 방법을 활용하였으며, 실험 결과는 그림 3과 표 6과 같다.

모든 모델은 90% 이상의 높은 정확도를 나타내었지만, 각 모델에 따라 성능에 미세한 차이가 있음을 확인할 수 있다. 학습 데이터셋에서 VGG16과 InceptionV3는 최고의 정확도인 99.96%를 보였는데, 이는 해당 모델들이 상대적으로 경량화되어 있으며 작은 데이터셋에서도 효과적으로 동작할 수 있음을 의미한다. 반면, ResNet50은 94.27%의 낮은 정확도를 기록했는데, 이는 ResNet50이 더 큰 데이터셋과 고해상도 이미지를 처리하는 데 최적화되어 있기 때문으로 추정된다. 즉, 실험에 사용된 이미지 데이터셋의 규모가 상대적으로 작기 때문에 VGG16과 InceptionV3는 우수한 성능을 발휘한 반면, ResNet50의 성능은 상대적으로 저하된 것으로 판단된다.

초기의 실험 단계에서 모든 모델은 낮은 정확도를 보였으나, 학습의 진행(즉, epoch의 증가)과 함께 정확

도는 점차 향상되고 손실은 감소하는 경향을 나타내고 있다. 또한, 특정 epoch를 초과한 이후에는 성능의 상승과 손실의 하강 폭이 점차 감소하는 것이 관찰되었으며, 이는 모델의 학습이 수렴하고 있음을 나타낸다.

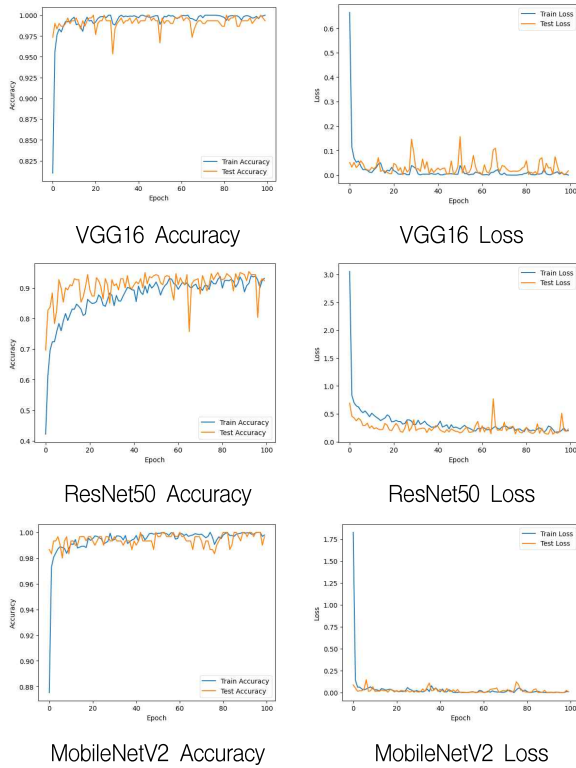


그림 3. 이미지 분류 모델의 정확도와 손실
 Figure 3. Accuracy and loss graphs of image classification models

표 6. 이미지 분류 모델의 성능 비교
 Table 6. The performance comparison of image classification models

Models	VGG16	ResNet50	InceptionV3
Train ACC	99.96%	94.27%	99.97%
Test ACC	99.33%	92.33%	99.66%
Train loss	0.0020	0.1640	0.0004
Test loss	0.0178	0.2272	0.0099

그림 3과 표 6에서 나타나듯이, 전이 학습을 통한 테스트 결과 InceptionV3 모델이 99.66%의 가장 높은 정확도를, ResNet50 모델은 92.33%의 가장 낮은 정확도를 확인할 수 있다. 이는 InceptionV3 모델이 본 연구의 실험 환경과 데이터셋에 가장 적합한 모델임을 의미하

며, ResNet50은 더 크고 복잡한 데이터셋에서 그 장점이 발휘될 가능성을 의미한다. 이러한 결과들은 드론 식별 및 분류 기술의 발전을 위한 중요한 기초 자료로 활용될 수 있을 것으로 기대된다.

V. 결론

본 연구는 최근 전장에서 핵심 기술로 주목받고 있는 드론의 식별 및 분류를 목적으로 시작하였다. 드론 및 이와 유사한 크기의 공중표적을 대상으로 데이터셋을 구성하였으나, 이미지 분류 모델 실험에 적용할 데이터셋의 규모가 상대적으로 작기 때문에, 적은 데이터에서도 우수한 성능을 보여주는 전이 학습 방식을 채택하였다. 이를 위해 사전 학습된 세 가지 CNN 기반 모델(VGG16, InceptionV3, ResNet50)의 특징 추출기와 추가 분류기를 결합하여 각 모델의 성능을 비교 및 분석하였다. 결과적으로 InceptionV3 모델이 가장 높은 정확도를 보였으며, ResNet50 모델이 가장 낮은 정확도를 나타내는 것을 확인하였다.

• 한계 및 제한사항: 본 연구는 주로 풍선과 새를 포함한 제한된 범위의 공중표적을 대상으로 데이터셋을 구성하였다. 이는 다양한 공중표적에 관한 포괄적인 연구를 수행하는 데 한계를 가지고 있다. 또한, 국방 분야에서 운용되는 실제 군용 드론 이미지를 주로 사용해야 하나, 군사보안 및 접근성의 제약으로 인해 인터넷에서 수집 가능한 군용 및 민간 드론 이미지를 활용하였다. 이로 인해 데이터셋의 대표성 및 실용성 측면에서 극복해야 할 제한사항을 포함하고 있다.

• 연구의 의의 및 향후 과제: 현재 드론 및 다른 공중 표적을 분류하는 연구는 상대적으로 부족한 상태이다. 이러한 상황에서, 본 연구는 전이 학습을 활용하여 기존의 방법들과는 다른 새로운 접근 방식을 제시하고 있으며, 이는 드론 식별 분야에서의 학문적 이해와 기술적 응용을 넓힐 수 있는 중요한 기여를 할 것으로 판단된다. 이러한 새로운 방법론은 향후 드론 식별 기술의 발전을 촉진하고, 다른 관련 기술의 발전에도 영향을 미칠 수 있는 중요한 기초 자료로 활용될 것이다.

향후 연구 과제로는 보다 충분하고 다양한 군용 드

론 데이터셋을 확보하여 더 폭넓은 공중표적에 대한 분류 및 식별 연구를 수행하는 것이다. 이를 통해 전장에 서 실질적으로 활용 가능한 드론 식별 시스템의 개발에 기여하고자 한다.

References

- [1] K.J. Lee, "A Study on the Development Plan and Analysis of Military Drone Standardization Promotion," *Journal of Review of Korean Military Studies*, Vol. 12, No. 1, pp.49-66, March 2023. DOI : 10.34166/rokms.2023.12.1.49.
- [2] B.Y. Um, "Study On Military Utility and Developmental Strategy for the Drones," *Journal of Military Research and Development*, Vol. 12, No. 2, pp.115-145, December 2018.
- [3] S.H. Park, S.K. Kim and S.P. Namgung, "A Study on Overseas battle Cases Using Combat Drone", *The Journal of the Convergence on Culture Technology(JCCT)*, Vol. 9, No. 5, pp.403-407, 2023. DOI : 10.17703/JCCT.2023.9.5.403
- [4] J.Y. Hwang, B.A. Choi, H.J. Lee and J.H. Bae, "A Study on Transfer Learning based Ensemble Model for Classification of Maneuver Weapon System," *Journal of Korean Institute Of Information Technology*, Vol. 19, No. 12, pp.1-10, 2021. DOI : 10.14801/jkiit.2021.19.12.1
- [5] 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," *Journal of Industrial Studies(J.I.S)*, Vol. 44, No. 1, pp.45-60, May 2020.
- [6] 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, 2020. DOI : 10.9766/KIMST.2020.23.2.115
- [7] Y.K. Lee, J.M. Ma, "A Comparative Study on the Performance of CNN Models for Classification of Artillery Weapon Systems," *Journal of The Korea Academia-Industrial cooperation Society*, Vol. 24, No. 1, pp.344-350, 2023. DOI : 10.5762/KAIS.2023.24.1.344
- [8] Z. Li, W. Yang, S. Peng, F. Liu, "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects," *IEEE transactions on neural networks and learning systems*, 2021. DOI : 10.1109/TNNLS.2021.3084827
- [9] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1904.1556*. 2014.
- [10] K. He, X. Zhang, S. Ren, J. Sun, "Deep residual learning for image recognition," *In Proceedings of the IEEE conference on computer vision and pattern recognition*, pp.770-778, 2016.
- [11] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, Z. Wojna, "Rethinking the inception architecture for computer vision," *In Proceedings of the IEEE conference on computer vision and pattern recognition*, pp.2818-2826, 2016.
- [12] <https://www.kaggle.com/datasets/>. [accessed: January. 8. 2024]