

Improved CNN Algorithm for Object Detection in Large Images

Seong Bong Yang*, Soo Jin Lee*

*Student, Dept. of Computer Science and Engineering, Korea National Defense University, Nonsan, Korea

*Professor, Dept. of Computer Science and Engineering, Korea National Defense University, Nonsan, Korea

[Abstract]

Conventional Convolutional Neural Network(CNN) algorithms have limitations in detecting small objects in large image. In this paper, we propose an improved model which is based on Region Of Interest(ROI) selection and image dividing technique. We prepared YOLOv3 / Faster R-CNN algorithms which are transfer-learned by airfield and aircraft datasets. Also we prepared large images for testing. In order to verify our model, we selected airfield area from large image as ROI first and divided it in two power n orders. Then we compared the aircraft detection rates by number of divisions. We could get the best size of divided image pieces for efficient small object detection derived from the comparison of aircraft detection rates. As a result, we could verify that the improved CNN algorithm can detect small object in large images.

▶ **Key words:** AI, Transfer Learning, CNN, Hi-resolution Large Image, Object Detection

[요 약]

기존의 CNN 알고리즘은 위성영상과 같은 대형 이미지에서 소형 객체를 식별하는 것이 불가능하다는 문제점을 가지고 있었다. 본 연구에서는 이러한 문제를 해결하기 위해 관심영역 설정 및 이미지 분할 기법을 적용한 CNN 알고리즘 개선방안을 제시하였다. 실험은 비행장 및 항공기 데이터셋으로 전환학습한 YOLOv3 / Faster R-CNN 알고리즘과 테스트용 대형 이미지를 이용하여 진행하였으며, 우선 대형 이미지에서 관심영역을 식별하고 이를 순차적으로 분할해 나가며 CNN 알고리즘의 객체식별 결과를 비교하였다. 분할 이미지의 크기는 실험을 통해 최소 분할로 최대의 식별률을 얻을 수 있는 최적의 이미지 조각 크기를 도출하여 적용하였다. 실험 결과, 본 연구에서 제시한 방안을 통해 CNN 알고리즘으로 대형 이미지에서의 소형 객체를 식별하는 것이 충분히 가능성을 검증하였다.

▶ **주제어:** 인공지능, 전환학습, CNN, 고해상도 대형 이미지, 객체인식

-
- First Author: Seong Bong Yang, Corresponding Author: Soo Jin Lee
 - *Seong Bong Yang (yangnal83@gmail.com), Dept. of Computer Science and Engineering, Korea National Defense University
 - *Soo Jin Lee (cyberkma@gmail.com), Dept. of Computer Science and Engineering, Korea National Defense University
 - Received: 2019. 10. 22, Revised: 2019. 12. 11, Accepted: 2019. 12. 11.

I. Introduction

영상정보는 군사 분야에서 적의 이상 징후를 판단하는데 중요한 역할을 하고 있으며, 인공위성이나 무인기 등 다양한 종류의 정찰자산들이 전력화되어감에 따라 입수되는 영상도 지속 증가하고 있다. 이에 기존의 숙련된 전문 인력만으로는 점증하는 영상의 분량을 효율적으로 판독해내는 데 한계가 있을 것으로 예상된다. 따라서 최근 각광받고 있는 AI 기반의 이미지 처리기술을 활용하여 기본적인 영상판독을 자동화한다면 이러한 문제를 해결할 수 있을 것으로 기대된다. 그러나 현재의 AI 기반 이미지 처리 기술은 주로 10메가픽셀 내외의 일반적인 사진 등에 사용되고 있으며, 위성영상과 같은 고해상도 대형 이미지에 대한 적용 가능 여부는 아직 검증된 바가 없다.

AI를 이용한 소형 객체식별에 관한 연구로는 영상 내에서 밀집된 객체들의 위치를 정확하게 분리하는 것[1]이나 Microsoft COCO 데이터셋 이미지에서 소형 객체를 다수 복사하여 Augmentation하는 기법[2], 일반적인 크기의 이미지에서 소형 객체를 식별하기 위해 기존의 CNN 알고리즘들을 개선하는 방안[3][4] 등이 있었지만, 앞서 언급한 대형 이미지에서의 소형 객체식별 문제에 관한 연구 사례는 거의 없었다.

본 연구에서는 25,000×15,000 픽셀(375메가픽셀)의 이미지를 대형 이미지로 정의하고 이를 대상으로 AI 기반 객체 식별 알고리즘을 이용한 자동영상판독을 실험한다. 그리고 실험 결과를 바탕으로 위성영상 판독업무에 AI 알고리즘을 적용하는 방안을 도출한다.

II. Preliminaries

2.1 Basic Structure of CNN Algorithm

CNN(Convolutional Neural Network)은 이미지 처리에 주로 사용되는 기계학습 알고리즘으로서 기본적인 구조는 그림 1과 같다[5]. 우선 Input Layer에 이미지가 입력되면 이를 동일한 크기의 작은 타일로 분할하고 각각을 숫자 형태로 변환하여 Convolutional Layer의 신경망에 제공한다. 여기서 처리된 타일들의 결과값은 Pooling Layer에 원본 이미지와 동일한 배열로 저장되는데, Fully Connected Layer에서는 이들 결과값과 식별 대상 이미지가 일치하는지 판단하고, Output Layer를 통해 최종 결과를 출력한다.




Fig. 1. Basic Structure of CNN [5]

CNN을 통한 이미지의 기계학습에서는 지도학습 기법이 주로 사용되며, 이는 데이터셋 작성 시 이미지에 라벨링을 함으로써 정답을 지정하는 방식이다. 기계는 이러한 데이터셋을 바탕으로 CNN의 Output Layer에서 출력된 값을 피드백하고 각 타일들에 대한 가중치를 조정함으로써 Input Layer와의 오차(Loss)를 최소화하는 과정을 반복한다. 처음에 각각의 타일들은 동일하게 취급되지만, 학습이 진행되면서 식별 대상과 관계가 있는 타일들에게는 추가적인 가중치가 부여된다. 또한 오차가 일정 수준 이하로 줄어들게 되면 학습률, 즉 가중치 조정의 보폭을 줄임으로써 목표치에 보다 정밀하게 접근한다. 이와 같이 이미지에서 객체를 식별하는 CNN 알고리즘은 Faster R-CNN[6], R-FCN[7], SSD[8], YOLO[9] 등 다양한 종류가 있으며, 정확성이나 인식속도 면에서 각기 차이를 보이고 있다.

한편 GAN(Generative Adversarial Networks)[10]과 같은 대표적인 비지도학습 알고리즘의 경우는 학습되지 않은 불특정한 객체를 식별해내는 데에 특히 우수한 능력을 발휘하지만, 본 연구를 적용하고자 하는 분야인 위성영상 판독업무는 식별하여야 할 객체의 종류와 유형이 특정되어 있어 데이터셋의 정답지를 통한 지도학습 방식이 보다 적절할 것으로 판단하여 CNN을 사용하였다.

2.2 Data Augmentation and Transfer Learning

CNN을 통한 객체인식을 위해서는 식별 대상에 대한 학습이 먼저 이루어져야 하는데, 새로운 객체의 이미지 데이터가 적을 경우에는 효과적인 학습이 이루어지기 어렵다. 이 때 객체의 각도나 위치, 크기 등을 변경하여 데이터셋에 추가하는 Data Augmentation 기법을 활용하면 학습에 필요한 분량의 데이터를 손쉽게 확보할 수 있다[11]. 또한, 사전에 다른 객체들로 학습이 완료된 알고리즘으로 생성된 가중치를 활용하는 전이학습 방식은 백지상태에 비해 상대적으로 적은 양의 데이터셋으로도 단시간 내에 우수한 학습효과를 기대할 수 있다[12].

III. Problem Definition

인공위성에서 한 번에 촬영되는 영역의 넓이는 통상 수 km^2 에 달하며, 2019년 현재 운용 중인 고성능 상용위성 Worldview-3의 해상도 0.31m[13]를 기준으로 하였을 경우 영상의 대략적인 크기는 1km^2 당 10.4메가픽셀 수준으로 매우 거대하다. 본 연구에서는 비행장 및 주변 지역을 포함한 375메가픽셀(약 $7.5\text{km} \times 4.5\text{km}$) 규모의 대형 이미지에서 CNN 알고리즘으로 항공기를 식별하는 것을 목표로 실험을 진행하였다. 이를 위해 YOLOv3[14]와 Faster R-CNN 알고리즘에 자체 제작한 항공기 위성영상 데이터셋을 전환학습시켰으며, 테스트 대상으로는 비행장 5곳의 Google Earth 영상을 합성한 대형 이미지를 사용하였다. 이와 같이 대형 이미지에서 곧바로 소형 객체 인식을 시도하여 본 결과 YOLOv3는 항공기를 전혀 식별해내지 못하였으며, Faster-R-CNN은 건물 일부 등을 항공기로 오인식별하는 등 정확성이 떨어지는 현상이 확인되었다. 즉, 기존의 CNN 알고리즘으로는 위성영상과 같은 대형 이미지에서 소형 객체를 직접 식별하는 것이 제한됨을 실험을 통해 확인하였다.

고 있음을 고려할 때, 객체 식별의 정확성은 이미지 내에서 객체 크기의 상대적 비율과 관련 있는 것으로 보인다. 그림 2에서 비교하는 바와 같이 동일한 해상도의 이미지라 하더라도 일부분을 잘라내어 작은 크기로 CNN 알고리즘에 입력하였을 경우에는 기존에 식별되지 못하였던 항공기들이 식별되거나 오인식별이 감소하는 등 정확도가 향상됨도 확인하였다.

본 연구에서는 CNN 알고리즘의 이러한 특징에 착안하여 대형 이미지 내에서도 소형 객체를 높은 정확도로 용이하게 식별할 수 있도록 하는 CNN 알고리즘의 개선 모델을 제시하고자 한다.

IV. The Proposed Scheme

4.1 ROI Detection and Large Image Division

III장에서 설명한 것처럼 위성영상과 같은 대형 이미지에서 항공기(Aircraft)와 같은 소형 객체를 식별하기 위해서는 그림 3에서와 같이 원본 이미지 전체보다는 비행장(Airfield) 등 해당 객체가 통상적으로 위치하는 시설을 먼저 관심영역(ROI : Region Of Interest)으로 설정하고, 탐색 범위를 해당 영역 내로 제한하는 것이 효율적이다.




Fig. 2. Relative Object Size and Precision Comparison

YOLOv3와 Faster R-CNN 알고리즘이 입력 이미지의 전체적인 형상에서 객체의 위치를 추출하는 특징을 가지

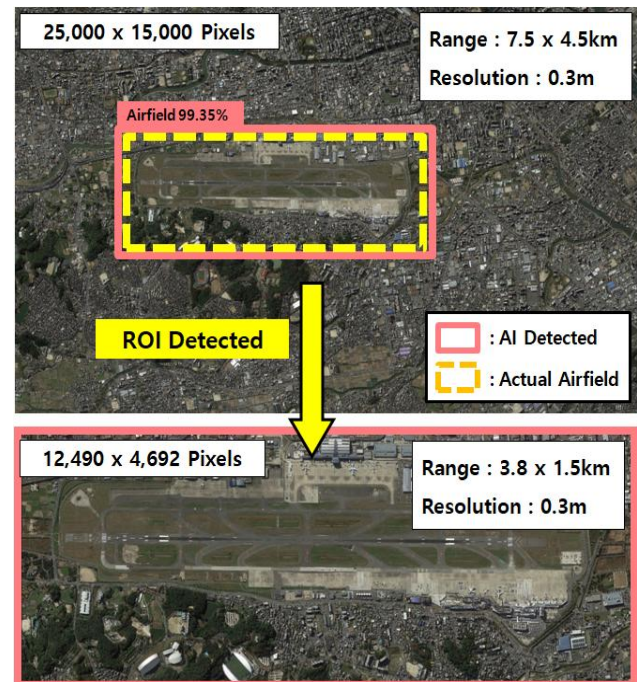


Fig. 3. Region of Interest(ROI) Detection

이를 위해 본 연구에서는 Google Earth 영상으로 자체 제작한 비행장 데이터셋을 Faster R-CNN과 YOLO 알고

리즘에 전환학습시킴으로써 대형 이미지에서 관심영역을 우선 식별하도록 하였다. 그러나 비행장과 같이 관심영역 자체가 광범위한 경우 항공기를 식별해내기에는 여전히 이미지가 너무 크므로 이를 최적의 식별률을 갖는 크기의 조각으로 분할하여 각각 처리하는 기법을 적용할 수 있다. 객체를 식별해내기 위한 최적의 이미지 조각 크기는 V장에서 후술하는 실험을 통해 도출한 결과 3,200×1,200 픽셀이다. 대형 이미지는 CNN 알고리즘에 입력되기 앞서 그림 4에서와 같은 방식으로 $j \times k (=n)$ 개의 조각으로 분할되며, CNN 알고리즘은 분할된 이미지를 행렬 순서로 처리한다.

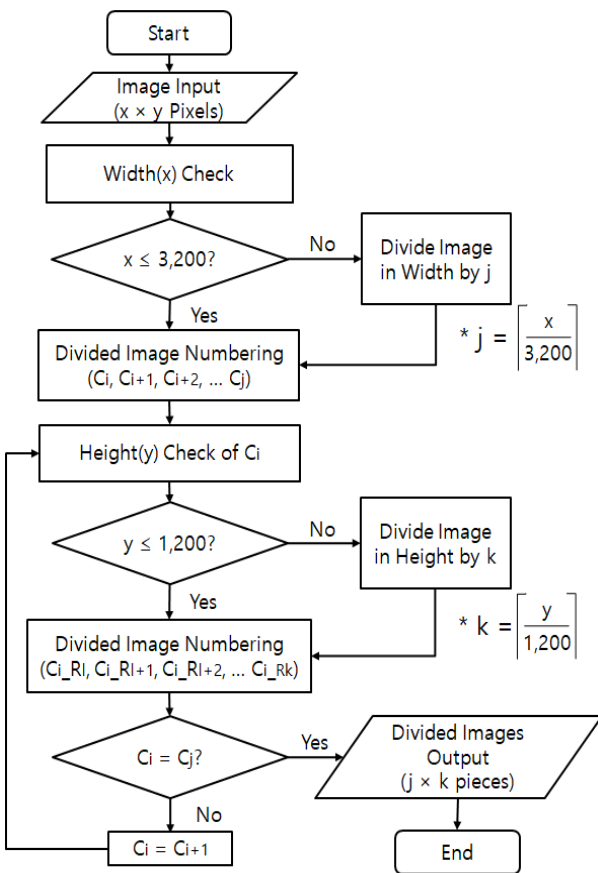


Fig. 4. Flowchart of Large Image Division

4.2 Adding New Layers to CNN Algorithm

그림 5에서와 같이 입력 이미지에서 관심영역을 식별하고 이를 분할하는 단계를 ‘Preprocessing Layer’로 정의하고, 분할된 이미지가 n개일 때 CNN 알고리즘은 객체를 식별하는 작업을 n번 실행한다.

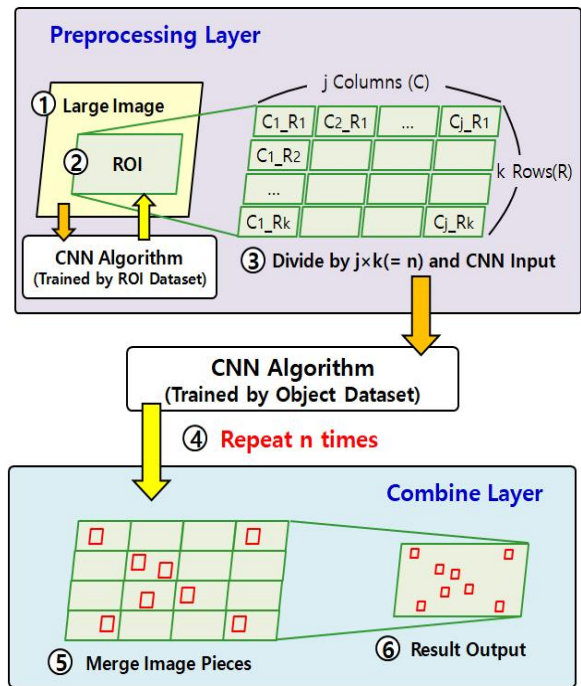


Fig. 5. Adding New Layers to CNN Algorithm

처리가 완료된 n개의 분할된 이미지를 원래 순서대로 배열하고 합성하는 ‘Combine Layer’에서는 식별결과가 표시된 하나의 이미지를 출력한다. 그런데 단일 객체가 이미지 분할 경계에 위치할 때에는 각각 별개로 식별될 수 있는데, 이런 경우에는 그림 6과 같이 가장 높은 확신도의 bounding box만 남기면서 중복을 제거한다.




Fig. 6. Deduplication of Bounding Boxes in Combine Layer

본 모델은 주요 CNN 알고리즘의 장점들을 융합하여 기존 CNN 알고리즘들의 단점을 보완하거나 장점의 강화를 시도한다. 대형 이미지에서 관심영역을 식별하는 단계에 예로 들면, YOLOv3 알고리즘은 Faster R-CNN의 RPN의 개념이 융합된 효과를 얻게 된다. 그리고 Faster R-CNN의 경우에는 특정 객체와 관련된 ROI로 학습된 가중치를 이용하여 RPN이 보다 정교화된 효과를 얻게 된다. 이처럼 본 모델에 특정 객체 및 해당 객체와 관련된 ROI가 학습된 가중치를 이용하면 CNN 알고리즘으로도 대형 이미지에서 우수한 객체 식별결과를 기대할 수 있다.

V. Experiments

5.1 CNN Algorithm Training

본 연구에서는 이미지에서 객체의 위치를 추출하는 방식에 따라 RPN(Region Proposal Network)의 개념을 사용하는 Faster R-CNN과, 이미지 크기 조정 후 CNN 처리의 방식을 사용하는 YOLOv3 알고리즘을 이용하여 실험을 진행하였다. 시스템 환경은 표 1과 같다.

Table 1. System Environment

Item	Value
CPU	RYZEN R7-2700U 2.2GHz
Memory Size	12GB
Tensorflow ver.	1. 13. 1
Keras ver.	2. 1. 2.
GPU Acceleration	None

우선 비행장을 관심영역으로 학습시키기 위해 그림 7과 같이 Google Earth로 세계 각지의 다양한 규모의 비행장 위성영상을 수집하여 데이터셋을 작성하였다. 각 이미지의 크기는 모두 1024×768 픽셀로 동일하며, 총 375매를 대상으로 Python 기반 Labelimg[15] 소프트웨어를 이용하여 비행장 외곽부분을 라벨링하였다. 학습과 테스트에 사용된 데이터는 각각 300매(라벨 300개)와 75매(라벨 75개)로, 8:2의 비율을 적용하였다.



Fig. 7. Samples of Airfield Dataset for ROI Training

항공기를 식별해내기 위한 데이터셋도 마찬가지로 그림 8과 같이 Google Earth 영상을 이용하여 작성하였다. 영상의 크기 및 매수는 비행장 학습데이터와 동일하게 모두 1024×768 픽셀에 총 375매이며, 학습과 테스트에 사용된 데이터 역시 각각 300매(라벨 1,489개)와 75매(라벨 354개)로 8:2의 비율을 적용하였다.



Fig. 8. Samples of Aircraft Dataset for Object Training

본 연구에서는 CNN 알고리즘의 학습 효과 증대를 위해 전환학습 및 Data Augmentation 기법을 함께 사용하였다. 학습은 Microsoft COCO와 VOC2012 데이터셋 등으로 사전 학습된 가중치에 상기 데이터셋을 학습시킨 뒤, 90도 회전된 이미지가 포함된 데이터셋을 추가 학습시키는 순으로 진행하였다. 먼저 YOLOv3 알고리즘은 최대 Epoch 횟수를 100으로 하고 3회 이상 연속으로 오차 (Loss)값 개선이 없을 시 조기 종료되도록 설정하였으며, 학습 진행 결과는 표 2 및 표 3과 같다.

Table 2. Training on YOLOv3 Algorithm (Airfield)

Subject	Original Dataset	Augmented Dataset	Total
Epochs	28	23	51
Elapsed Time	36h 44m	26h 42m	63h 26m
Images	300	300	600
Pretrained Dataset	Microsoft COCO		

Table 3. Training on YOLOv3 Algorithm (Aircraft)

Subject	Original Dataset	Augmented Dataset	Total
Epochs	27	26	53
Elapsed Time	29h 11m	28h 20m	57h 31m
Images	300	300	600
Pretrained Dataset	Microsoft COCO		

한편 Faster R-CNN 알고리즘은 총 학습 소요시간을 YOLOv3과 비슷한 수준으로 조정하기 위해 Epoch를 10회로 설정하였으며, 진행 결과는 표 4 및 표 5와 같다.

Table 4. Training on Faster R-CNN Algorithm (Airfield)

Subject	Original Dataset	Augmented Dataset	Total
Epochs	10	10	20
Elapsed Time	32h 30m	36h 22m	68h 52m
Images	300	300	600
Pretrained Dataset	VOC2012		

Table 5. Training on Faster R-CNN Algorithm (Aircraft)

Subject	Original Dataset	Augmented Dataset	Total
Epochs	10	10	20
Elapsed Time	30h 10m	37h 44m	67h 54m
Images	300	300	600
Pretrained Dataset	VOC2012		

5.2 CNN Object Detection Test

이와 같이 학습을 완료한 CNN 알고리즘으로 IV장에서 제안하였던 기법의 효용성을 검증하기 위해 데이터셋에 미포함된 비행장 5곳의 주변지역 대형 이미지를 별도로 준비하여 객체식별 실험을 진행하였다.

우선 비행장 데이터셋으로 학습된 가중치를 통해 대형 이미지로부터 관심영역을 잘라낸 뒤, 이를 분할하여 항공기 데이터셋으로 학습된 가중치로 객체를 식별하였다. 정확도를 쉽게 확인하기 위해 출력 이미지에는 확신도 98% 이상의 객체만 표시하도록 설정하였으며, 주요 분할 크기별 식별 결과는 그림 9~12와 같다.

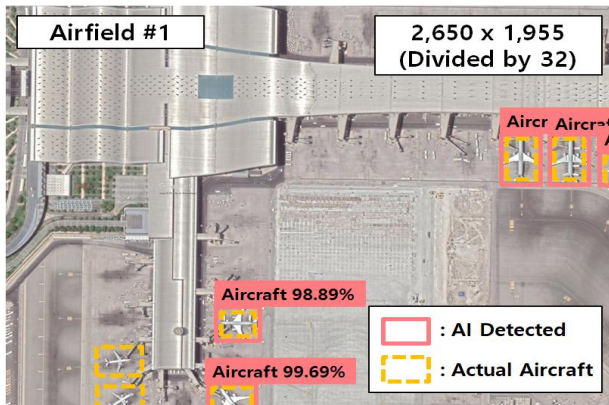


Fig. 9. Object Detection Result (YOLOv3 / 2,650x1,955)

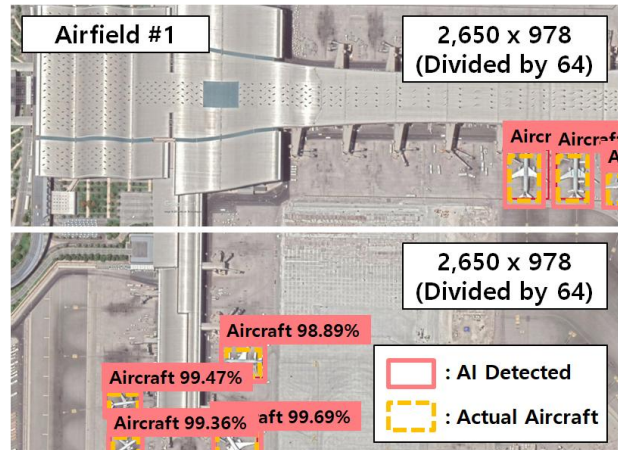


Fig. 10. Object Detection Result (YOLOv3 / 2,650x978)

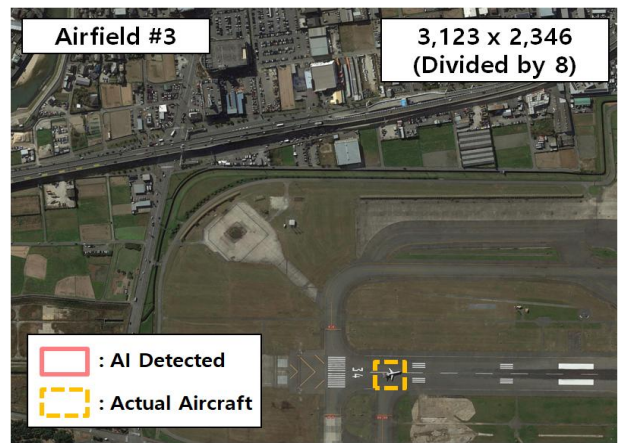


Fig. 11. Object Detection Result (Faster R-CNN/3,123x2,346)

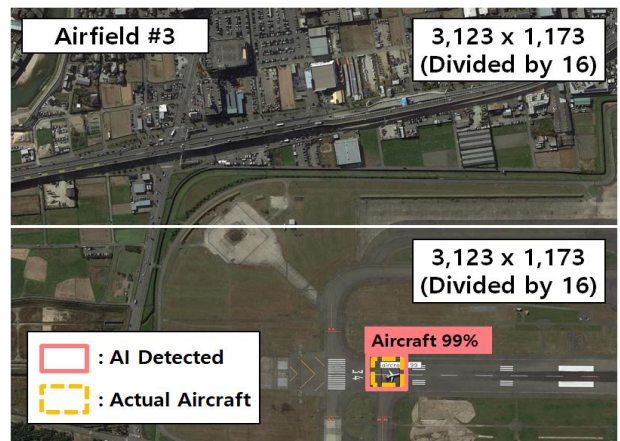


Fig. 12. Object Detection Result (Faster R-CNN/3,123x1,173)

이처럼 관심영역 식별 및 분할 기법을 추가 적용하면 그림 13과 같이 기존의 CNN 알고리즘으로도 위성영상과 같은 대형 이미지에 대하여 충분히 우수한 객체식별 결과를 얻을 수 있다. 또한, 식별하고자 하는 소형 객체와 관련이 없는 영역을 초기 단계에서 배제함으로써 신속한 처리속도와 시스템 부담 경감을 기대할 수 있다.

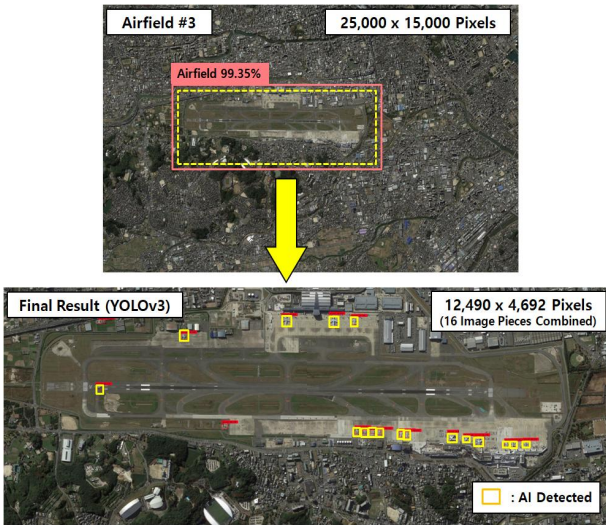


Fig. 13. Final Result of Proposed Model (YOLOv3)

한편 그림 14, 15에서와 같이 CNN 알고리즘이 건물 등 다른 객체를 항공기로 오인식별한 사례도 일부 확인되었는 바, 이러한 문제에 대해서는 향후 학습 데이터셋의 정밀화 등을 중점으로 추가 연구를 실시할 예정이다.




Fig. 14. Odd Case (YOLOv3 / Divided by 3,000x1,125)




Fig. 15. Odd Case (Faster R-CNN / 3,000x1,125)

5.3 Optimal Size of Images for Object Detection

대형 이미지에서 소형 객체를 식별하기 위한 최적의 분할 조건은 최소 개수로 나뉘어짐과 동시에 각 조각이 최대의 식별률을 유지하는 것이다. 본 실험에서는 이를 도출하기 위해 표 6~8에서와 같이 이미지를 2ⁿ개의 조각으로 등분해 나가면서 실제 항공기의 대수와 CNN 알고리즘이 식별해낸 항공기의 대수를 비교하였다.

Table 6. Object Detection Result Comparison (#1)

Airfield #1 (Total Number of Aircrafts : 26)			
Div.	IMG Size (Pixel)	Detection Rate	
		YOLOv3	Faster R-CNN
1	21,200x7,820	0%	0%
2	10,600x7,820	0%	0%
4	10,600x3,910	0%	8%
8	5,300x3,910	42%	4%
16	5,300x1,955	62%	50%
32	2,650x1,955	81%	50%
64	2,650x978	100%	96%

Table 7. Object Detection Result Comparison (#2)

Airfield #2 (Total Number of Aircrafts : 126)			
Div.	IMG Size (Pixel)	Detection Rate	
		YOLOv3	Faster R-CNN
1	24,000x9,000	0%	0%
2	12,000x9,000	0%	0%
4	12,000x4,500	0%	8%
8	6,000x4,500	16%	12%
16	6,000x2,250	34%	47%
32	3,000x2,250	78%	49%
64	3,000x1,125	92%	85%

Table 8. Object Detection Result Comparison (#3)

Airfield #3 (Total Number of Aircrafts : 17)			
Div.	IMG Size (Pixel)	Detection Rate	
		YOLOv3	Faster R-CNN
1	12,490x4,692	6%	6%
2	6,245x4,692	12%	0%
4	6,245x2,346	35%	47%
8	3,123x2,346	65%	35%
16	3,123x1,173	100%	88%

이상과 같이 각 테스트 이미지에 대한 식별률을 종합한 결과, 앞서 설명한 최적의 이미지 분할 조건에 부합하는 조각의 크기는 약 3,200x1,200 픽셀 이하인 것으로 판단되어 IV장에서 제안한 분할모델에 반영하였다.

VI. Conclusions

본 연구에서는 기존의 CNN 알고리즘이 대형 이미지에서 소형 객체를 식별할 수 없는 문제를 해결하기 위해 관심영역 식별 및 분할 기법을 적용한 CNN 알고리즘의 개선 모델을 제안하였다. 본 모델은 관심영역과 객체로 사전학습이 이루

어진 CNN 알고리즘을 바탕으로 Preprocessing Layer에서의 관심영역 식별과 최종적인 객체식별을 서로 독립적으로 진행하므로 최상의 결과를 얻기 위해 다양한 종류의 CNN 알고리즘을 혼합 가동할 수 있다는 장점이 있다. 이를 통해 기존의 YOLOv3 알고리즘에는 Faster R-CNN의 RPN의 개념이 융합된 효과가, Faster R-CNN에는 RPN이 보다 정교화된 효과를 얻을 수 있었다. 여기에 특정 객체 및 해당 객체와 관련된 ROI가 학습된 가중치를 이용하면 대형 이미지에 서도 우수한 식별결과를 얻을 수 있으며, 이는 비행장과 항공기의 위성영상을 이용한 실험을 통해서도 검증되었다.

한편 본 연구에 사용된 YOLOv3과 Faster R-CNN 알고리즘의 성능을 비교하여 본 결과, 표 6~8에서 보는 바와 같이 YOLOv3의 객체 식별률이 더 높음을 확인할 수 있었다. 이는 YOLOv3의 학습 소요시간을 기준으로 Faster R-CNN의 학습 Epoch 반복 횟수를 조정하였기 때문이며, 만약 더 많은 횟수의 Epoch로 학습을 진행하였다면 Faster R-CNN도 식별률 개선의 여지가 있을 것으로 예상된다. 그러나 군의 임무 수행에는 정확성 못지않게 신속성도 중요한 가치를 가지며, 주어진 시간 내에 더 우수한 성과를 도출해내는 것이 매우 중요하다. 그런 측면에서 보았을 때 YOLOv3 알고리즘은 군이 요구하는 기준에 보다 효과적으로 부응할 수 있을 것으로 판단된다. 그리고 본 연구에서는 분할된 이미지의 개수만큼 CNN 알고리즘이 순차적으로 객체식별 절차를 반복하였으나, 고성능 GPU가 장착되어 있으면서 병렬처리를 지원하는 시스템에서 구동할 경우에는 보다 신속한 판독임무 지원이 가능할 것이다.

현 시점에서 AI기반 이미지 처리기술을 활용한 군사용 위성영상 판독임무 지원은 시작 단계에 불과하지만, 끊임 없는 연구와 관련 소프트웨어 개발이 지속적으로 이루어진다면 향후 점증하는 영상판독 수요에 능동적으로 대처 가능한 기반을 마련할 수 있을 것이다.

REFERENCES

- [1] J. Yu, et al., "Improving Performance of YOLO Network Using Multi-layer Overlapped Windows for Detecting Correct Position of Small Dense Objects," Journal of The Korea Society of Computer and Information Vol. 24 No. 3, pp. 19-27, March 2019. DOI: 10.9708/JKSCI.2019.24.03.019.
- [2] M. Kisantal, et al., "Augmentation for small object detection," Computer Vision and Pattern Recognition (CVPR) February 2019. arXiv:1902.07296v1
- [3] G. Cao, et al., "Feature-fused SSD: fast detection for small objects," 9th International Conference on Graphic and Image Processing (ICGIP), April. 2018. DOI: 10.1117/12.2304811
- [4] Y. Ren, et al., "Small Object Detection in Optical Remote Sensing Images via Modified Faster R-CNN," Multidisciplinary Digital Publishing Institute (MDPI), May 2018. DOI: 10.3390/app8050813
- [5] M. Peng, C. Wang, T. Chen, G. Liu., "NIRFaceNet: A Convolutional Neural Network for Near-Infrared Face Identification," Information, Vol. 7, No. 4, pp. 61, October. 2016. DOI: 10.3390/info7040061
- [6] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards real-time object detection with region proposal networks," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 15, Issue. 6, pp. 1137-1149, June. 2017. DOI: 10.1109/TPAMI.2016.2577031
- [7] J. Dai, Y. Li, K. He, and J. Sun, "R-FCN: Object Detection via Region-based Fully Convolutional Networks," Neural Information Processing Systems(NIPS), 29, May. 2016. arXiv:1605.06409
- [8] W. Liu, et al., "SSD: Single Shot MultiBox Detector." European Conference on Computer Vision(ECCV) 2016, pp. 21-37, September. 2016. DOI: 10.1007/978-3-319-46448-0_2
- [9] J. Redmon, et. al., "You Only Look Once: Unified, Real-Time Object Detection," The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 779-788. June. 2016. DOI: 10.1109/CVPR.2016.91
- [10] I. Goodfellow, et al., "Generative Adversarial Networks" Neural Information Processing Systems(NIPS), June. 2014. arXiv:1406.2661v1
- [11] A. Mikołajczyk, and M. Grochowski., "Data augmentation for improving deep learning in image classification problem," Conference: 2018 International Interdisciplinary PhD Workshop (IIPHDW), pp. 117-122. May. 2018. DOI: 10.1109/IIPHDW.2018.8388338
- [12] H. Shin, et. al., "Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning," The IEEE Transactions on Medical Imaging, Vol. 35, No. 5, pp. 1285 ~ 1298. May. 2016. DOI: 10.1109/TMI.2016.2528162
- [13] Digitalglobe. com., "Worldview-3 Data sheet," 2017, https://dgv4-cms-production.s3.amazonaws.com/uploads/document/file/128/DG2017_WorldView-3_DS.pdf
- [14] J. Redmon, and A. Farhadi, "YOLOv3: An Incremental Improvement," Computer Vision and Pattern Recognition (cs.CV), April. 2018. arXiv:1804.02767
- [15] Tzutalin, "LabelImg," Git code, <https://github.com/tzutalin/labelImg>

Authors



Seong Bong Yang received the B.A. degree in International Relationship from Air Force Academy, Korea, in 2007. He is now working toward a M.S. degree at Department of Computer Science and Engineering,

Korea National Defense University. He is interested in Cyber Warfare Policy, Machine Learning, Image Processing, AI Algorithm-based Object Detection.



Soo Jin Lee received the B.S. degree from Korea Military Academy in 1992, M.S. degree in Computer Science from Yonsei University in 1996, and Ph.D. degree in Computer Science and Engineering from

Korea Advanced Institute of Science and Technology in 2006. Dr. Lee is currently a Professor in the Department of Computer Science and Engineering at Korea National Defense University, Nonsan, Korea, from 2006. He is interested in Cyber Warfare and Cyber Security Policy, Intrusion Detection System, Mobile Network Security, Encryption theory and applications.