

UAV 영상 기반의 Faster R-CNN 기법을 활용한 샌드위치패널 지붕탐색

Sandwich Panel Roof Exploration Using UAV Image-Based Faster R-CNN Technique

노 태 완* · 박 기 현**

Noh, Tae Wan · Park, Ki Heon

요 약

우리나라 건축물 중 샌드위치패널(조립식판넬) 건축물은 건축시장에서 선호되지만 화재에 취약한 건축자재로 분류된다. 샌드위치패널(조립식판넬) 건물의 화재는 화재의 빠른 확산으로 인해 짧은 시간에 대형 화재로 이어질 가능성이 높으며, 다른 건물에 비해 인명 및 재산 피해의 주요 원인이 되는 건물 붕괴 위험이 높다. 화재로 인한 인명 및 재산 피해를 방지하기 위해서는 화재에 취약한 건축물에 대한 관리가 절실히 필요한 실정이다. 따라서 본 연구에서는 항공사진보다 영상 획득이 용이한 무인항공기(UAV)와 최근 활발히 활용되고 있는 CNN의 객체 탐지 알고리즘을 결합하여 화재에 취약 건물의 지붕을 탐색하고 분류하는 방법을 제안하였다. 구체적으로, UAV로 촬영한 영상에서 화재가 발생하기 쉬운 지붕을 탐색 및 분류할 때 다양한 촬영 고도에서 촬영한 UAV 영상을 제작하여 학습 데이터로 활용하고, 또 다른 학습 데이터와 비교하여 화재 취약 건물 지붕을 감지하기 위한 최적의 조건을 찾는 것이다.

주요어 : 무인항공기, Faster R-CNN, 샌드위치패널, 객체 탐지 알고리즘

ABSTRACT

Among the buildings in Korea, sandwich panel buildings are classified as building materials that are preferred in the building market but vulnerable to fire. The fire in the sandwich panel building is likely to lead to large fires in a short time due to the fast spread of fire and the risk of building collapse is considerable compared to other buildings, which is the main cause of human and property damage. In order to prevent human and property damage from fire, management of buildings vulnerable to fire is desperately needed. Therefore, in this work, we proposed a method to explore and classify the roofs of vulnerable buildings in fire by combining unmanned aerial vehicles (UAV) that are easier to obtain images than aerial photographs and CNN's recently actively utilized object detection algorithms. Specifically, when exploring and classifying fire-prone roofs from images taken with UAV, the objective is to build and use images taken at various shoot elevations as learning data, and to find optimal conditions for detecting roofs of buildings by comparing results when another learning data is added to learning data.

Keywords : UAV Image, Faster R-CNN, Sandwich Panel, Object Detection Algorithms

* 주저자, 정회원·경북대학교 일반대학원 공간정보공학과 석사(E-mail: taewan@dggis.kr)

** 교신저자, 정회원·경일대학교 부동산지적학과 조교수(E-mail: khpark@kiu.kr)

1. 서 론

최근 드론을 활용하는 기술들이 발전하고 전 세계적으로도 드론에 대한 관심이 높아지고 있다. 드론산업은 조사, 측량, 문화재, 토목, 방송, 방제, 재난 및 방재 등 각종 산업에서 활용되고 있으며 고정밀 위치정보와 이에 따른 공간정보 산업은 자율주행자동차 및 측량 관련 기술이 환경변화에 따라 드론과 첨단 정보통신 기술, AI(인공지능) 분야와 융합하여 무한한 가능성을 보여주고 있다(조혜진, 2017).

화재의 초기 진압과 감시 등의 화재와 관련하여 드론의 활용도 역시 높아지고 있는 실정이다. 그러한 화재 중에서 샌드위치패널 건축물의 화재는 불의 확산속도가 빨라 짧은 시간에 대형화재로 이어지기 쉽고 건물붕괴의 위험성이 다른 건물들에 비해 상당히 높아 인명과 재산의 피해를 키우는 주원인이 된다. 샌드위치패널은 건축시장에서 선호하는 건축자재이지만 표면재의 약한 내구성과 심재의 용융·연소성으로 인해 화재에 취약한 건축자재로 분류되고 있다. 1999년 씨랜드 청소년 수련원에서 발생한 화재로 23명이 사망하고 6명이 부상을 입었으며, 2008년 1월 이천 냉동 창고 화재는 40명이 사망하고 9명이 부상을 입었다. 또한 2008년 12월에는 이천 물류 창고 화재로 8명이 사망하고 2명이 부상을 입었다. 이 외에도 2020년 4월 이천 물류창고 화재로 38명이 사망하였으며 10명이 부상을 당하는 화재도 샌드위치패널 건축물의 화재로 많은 인명과 재산피해를 가져왔다.(다음노컷뉴스) 이처럼 화재로부터 인명과 재산상의 피해를 막기 위해서는 화재에 취약한 건축물들의 관리가 절실히 필요하다.

우리 주변 곳곳에 있는 샌드위치패널 구조의 건축물들의 현황과 분포를 탐지하고 확인하기 위해 전통적인 공간정보의 구축 방법으로는 건축물관리대장의 속성정보를 이용하거나 항공사진측량기법을 이용하여 대상지역의 지형 및 건축물을 데이터베이스화 하는 방법이 있다. 하지만 막대한 비용

과 인력, 기상상황의 제약, 복잡한 작업절차 및 법적 준비절차, 화재에 취약한 건축물의 분류, 데이터베이스화 이후의 갱신 등은 빠른 대처가 필요한 곳에는 제약이 크다 할 수 있다.

그러므로 본 연구에서는 위성영상 또는 항공사진보다 상대적으로 고해상도의 영상 취득이 가능하고 기상 및 법적 준비절차의 큰 제약 없이 실시간으로 데이터 취득이 가능한 UAV(무인항공기)와 최근 활발히 활용되고 있는 CNN의 객체탐지 알고리즘을 접목하여 화재의 취약한 건축물의 지붕을 탐색하여 분류하는 방법을 제시 하고자 한다.

본 연구와 관련된 선행연구들을 조사한 결과 <표 1>과 같이 촬영된 영상이나 이미지를 처리하는 기법과 영상에서 건축물이나 시설물에 대한 공간정보의 취득과 재해나 재난의 피해현황 등을 추출하는 연구들이 다수였다. 또한 AI기술을 이용한 연구들은 주로 도로와 차량에 집중할 수 있는 기술이 대부분이거나 실시간 영상을 이용하는 기술이 대부분이었다. UAV 영상을 활용하여 CNN기법을 활용하여 건축물을 분류하는 연구는 거의 전무한 상태이며 건축물과 관련된 연구들도 정사영상에 대한 부분수정이나 수치지형도상의 건축물 레이어를 수정하는 연구 또는 지형도상의 건축물과 영상에서 추출한 건축물 외곽선을 비교하는 연구만 확인할 수 있었다.

<표 1> 선행연구

저 자	내 용
함상우 (2019)	딥러닝을 이용한 드론 영상 의미론적 분할 (서울시립대학교 석사학위논문)
조혜진 (2017)	드론을 이용한 영상취득 및 영상처리에 관한 연구(경북대학교 석사학위논문)
김병준 (2017)	Faster R-CNN기법을 이용한 옥외 영상 차량 번호판 검출(전북대학교 석사학위논문)
고명진 (2017)	Faster R-CNN을 이용한 갯길 차로 위반 차량 검출(연세대학교 석사학위논문)
김선웅 (2020)	딥러닝 기반 OGC 웹 프로세싱 서비스를 이용한 드론영상 자동 분류에 관한 연구(건국대학교 박사학위논문)

신창수 (2021)	무인항공기를 이용한 건축물 정사영상 부분수정 연구(서울시립대학교 박사학위논문)
안호연, 이종택(2018)	실제 도로환경에 적합한 Faster R-CNN 기반 차종분류(한국지능시스템학회, 제28권, 제3호)
이한술 (2018)	사물 인식을 위한 효율적인 딥러닝 플랫폼(숭실대학교 석사학위논문)
김재중 (2021)	드론영상을 활용한 도로위험도 산정과 위험 정보 제공의 효과(한밭대학교 석사학위논문)
이유진 (2020)	드론으로 획득한 다중분광영상의 정사영상 생성 및 정확도 평가(충남대학교 석사학위논문)
최미형 (2021)	딥러닝 기반의 객체인식기술을 이용한 보도블럭 파손등급 검출 및 인식(부산대학교 석사학위논문)
김태환 (2019)	영상개체인식을 위한 딥러닝 알고리즘 비교(동국대학교 석사학위논문)
이선화 (2019)	천리안 자료 기반 Faster R-CNN을 활용한 태풍 식별 및 강도·중심위치 산출(고려대학교 석사학위논문)
유종근 (2018)	산림지역 개발 계획을 위한 드론사진측량의 활용(상지대학교 석사학위논문)

따라서 본 연구에서는 UAV를 이용하여 건축물의 지붕을 고해상도의 영상으로 촬영하고, 화제에 취약한 건축물들의 지붕을 선별 학습시켜 대상 CNN 알고리즘을 이용하여 화제에 취약한 샌드위치패널 구조의 건축물을 분류하였다. 또한 분류 시 UAV 영상의 해상도와 학습데이터의 추가가 분류 결과에 미치는 영향을 비교·분석하여 건축물의 지붕을 탐지하는 최적의 조건을 제시하였다.

본 연구의 실험 및 분석을 위한 공간적 범위는 경상북도 경산시 삼풍동과 계양동 일대 주거지역으로 선정하였다. 법적 규제 없이 촬영 및 비행 가능한 지역 중에서 주거 밀집지역으로 아파트, 빌라, 연립주택, 단독주택뿐만 아니라 샌드위치패널 구조의 조립식 창고, 냉동 창고, 마트 등 다양한 건축물들이 산재해 있어 실험에 적용할 학습데이터 구축이 용이하다고 판단되는 지역을 선정하였다. UAV 이미지는 2020년 09월 26일, 2021년 3월 23일 총 두 번에 걸쳐 촬영한 이미지를 활용하였

다. 2020년 09월에 촬영한 영상은 촬영고도 150미터에서 촬영하였으며, 2021년 3월에 촬영한 영상은 촬영고도 80미터와 100미터에서 각각 촬영하였다. 고해상도의 이미지 촬영을 위해 촬영고도 60미터를 계획하였으나 작업 대상지역에 고층 아파트가 위치해 있어 안전상의 이유로 80미터와 100미터, 150미터의 고도로 촬영을 진행하였다.

2. 촬영 및 정사영상 제작

2.1 촬영대상 지역

본 연구 지역은 경상북도 경산시 소재의 비행 및 촬영 금지구역이 아닌 삼풍동, 계양동, 사동 일대의 도심 속 주거지역으로 주거용 건물과 주택, 상가, 창고 등 다양한 건축물들이 있어 실험대상 지역으로 본 연구를 수행하기에 가장 적합하다고 판단하여 선정하였다.



[그림 1] 촬영대상 지역

[그림 1]은 1차 학습 지역(촬영고도 80미터 244매, 촬영고도 100미터 172매)과 2차 학습 지역(촬영고도 80미터 290매, 촬영고도 100미터 218매, 150미터 96매), 테스트 지역(촬영고도 90미터 229매중 테스트 용도로 사용할 이미지 57매)을 나타내고 있다.

〈표 2〉 관측장비 및 제원

구 분	사 양	특 징
	무게	734g
	GPS 모드	GPS/GLONASS
	비행속도 및 고도	최대 상승속도: 5m/s, 최대 하강 속도: 3m/s 최고속도: 65km/h, 최대 비행 고도: 5,000m 최대 비행 시간: 27분
짐벌	제어 가능 범위	피치 -90° to +30°
비전 포지셔닝	범위	속도 범위 : 36km/h(지상2m) 고도, 작동 범위 : 0.3m~13m
	기본사양	작동 주파수: 2.4GHz~2.483GHz 전송거리: 7km(FCC) 조종기 배터리: 2,970mAh 송신기 전력(ERP): FCC: 26dBm, CE: 20dBm
	기본사양	1/2.3인치 CMOS 센서, 유효픽셀 1,200만 화소 최대 이미지 크기 : 4,000×3,000, 26mm(35mm환산) F2.2 ISO범위 : 100~3,200(Video), 100~1,600(Photo)
	비디오 녹화 모드	4k : 3,840×2,160 24/25/30p
	스틸 사진 모드	Single shot, Burstshooton 3/5/7frames, 자동노출: 0.7
	지원되는 파일 형식	FAT32, exFAT, Photo : JPEG, DNG Video : MP4, MOV (MPEG~4, AVC/H.264)

2.2 관측장비 및 촬영

본 연구에서 드론측량에 사용된 장비는 DJI사의 매빅프로(Mavic Pro)를 사용하였다. 드론을 이용한 항공사진촬영은 지상기준점 측량을 이용하여 높은 정밀도의 영상을 취득할 수 있지만 본 연구에서는 드론 내에 탑재되어 있는 GPS만을 이용하여 정사영상 제작 및 학습데이터를 구축하였다. 드론 촬영은 Pix4D capture를 이용하여 촬영드론, 촬영위치, 고도, 비행경로, 중첩도, 비행속도 등을 설정하여 지정한다. 촬영방식은 정사영상을 제작하므로 2D Grid(90도)를 지정하였다.

2.3 정사영상 제작

정사영상을 제작함에 있어 측량용으로 위치정확도가 확보된 정밀한 정사영상이 필요한 것이 아

니다. 앞서 서론에서도 언급한 바와 같이 화재에 취약한 건축물을 적은 비용과 최소한의 시간이 소요되는 간편한 방법으로 탐지하기 위한 실험의 목적에 맞게 지상기준점 측량없이 사진에 포함된 GPS 정보만을 이용하여 정사영상을 제작하였다.

본 연구에서는 학습을 위해 촬영된 항공사진의 자료처리를 위해 Agisoft사의 PhotoScan Professional 버전을 사용하였다. PhotoScan은 영상을 이용하여 3D모델링이 가능한 솔루션이다. PhotoScan을 이용한 정사영상을 제작하는 순서는 [그림 2]와 같다. [그림 3]은 제작한 정사영상 이미지와 이미지 내에 학습할 샌드위치패널 구조의 지붕을 마킹한 이미지이다. 이 마킹을 기초로 하여 각각의 이미지에 Bounding box를 처리하였다.



〔그림 2〕 정사영상 제작 흐름도



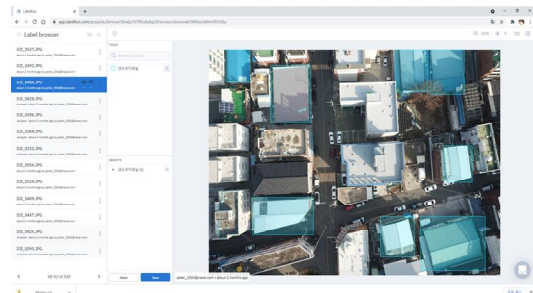
〔그림 3〕 샌드위치 패널 지붕 마킹

3. 데이터셋 구축 및 학습

3.1 데이터 가공

객체 탐지 학습모델을 만들기 위해서는 촬영한 이미지에 Bounding Box를 만들어야 한다. 객체 탐지 모델에 사용되는 데이터의 크기가 상당히 크기 때문에 Bounding Box를 통해 객체를 탐지하고 효율적으로 학습할 수 있기 때문이다. Bounding Box는 객체의 위치를 특정하기 위해 사용되며 X와 Y축을 이용하여 사각형으로 표현한다.


본 연구에서는 Labelbox.com사이트에서 이미지 라벨처리(Bbox)를 진행하였다. 사이트에 접속하고 Project를 생성하고 학습할 이미지들을 업로드 하고, 이미지가 업로딩 되면 편집기를 통해서 Bounding box의 이름과 형태를 선택하여 설정을 완료하였다.



〔그림 4〕 bounding box 작업

[그림 4]는 이미지에 해당하는 객체가 있는 영역을 Bounding box로 영역을 설정한 후 영역의 범위는 객체가 완전히 영역 안에 포함되도록 설정하여야 하며 중복되는 영역은 중복되게 설정한 것이다. [그림 4]의 오른쪽 이미지에 샌드위치패널 구조의 지붕에 영역을 설정하였다. Bounding box Label 처리가 완료되면 JSON¹⁾파일 Format으로 Export를 실행하였다.

1) JSON파일 포맷은 XML을 대체하는 주요 데이터포맷으로 데이터객체를 전달하기 위해 인간이 읽을 수 있는 텍스트를 사용하는 개방형 표준포맷이다.



(그림 5) 데이터 셋 생성

JSON파일은 데이터셋을 만들기 위해 Roboflow.com사이트에서 지역별, 촬영고도별로 Bounding box를 입력하여 이미지를 추가하였다.


추가된 이미지는 학습과 검증을 위해 Train(모

델을 훈련하기 위해 사용할 이미지)/Valid(훈련된 모델 중에서 최종 모델을 선정하기 위한 성능평가)/Test(학습한 데이터를 검증할 이미지)로 분리해서 데이터셋을 생성하였다. 학습에 전체 데이터를 사용하지 않는 이유는 과적합(Over-fitting)²⁾을 피하고 학습데이터를 사용해서 생성한 모델의 정확도를 검증하여 최적의 모델을 선택하기 위해서이다. 학습을 위한 이미지가 3개(Train/Valid/Test 7:2:1의 비율)의 폴더로 분리되면 Tensorflow TFRecord³⁾ Format으로 데이터셋을 생성한다.


생성된 데이터셋은 각각의 폴더에 데이터를 확인할 수 있다. 데이터셋은 촬영고도별(80미터, 100미터), 추가 학습데이터(1차지역, 2차지역)별 각각 데이터셋을 생성한다.



(a) 촬영고도 150미터 촬영 이미지



(b) 촬영고도 100미터 촬영 이미지




(c) 촬영고도 80미터 촬영 이미지

(그림 6) 촬영고도별 학습 영상


- 2) 과적합은 기계학습에서 학습 data를 과하게 학습하는 것을 뜻하는 것으로 일반적으로 학습 data는 실제 data의 부분 집합이므로 학습data에 대해서는 오차가 감소하지만 실제 data에 대해서는 오차가 증가하게 된다.
- 3) Tensorflow에서 지원하는 파일 형식이며 Tensorflow로 딥러닝 학습할 때 필요한 데이터를 보관하기 위한 데이터 포맷이다.

3.2 데이터셋 구축



[그림 7] 2차 학습지역의 추가 학습 데이터

데이터셋 구축을 위해 동일한 이미지 학습지역에 대해서 촬영고도(80미터, 100미터, 150미터)를 다르게 하여 [그림 7]과 같이 촬영하였다. 촬영고도 80미터로 촬영한 이미지 매수는 총 244매이며 촬영고도 100미터로 촬영한 이미지는 총 172매, 촬영고도 150미터로 촬영한 이미지는 총 96매이다. 촬영고도가 높아짐에 따라 중첩도를 조금씩 줄인 결과 촬영매수는 줄어들었다.



[그림 8] 학습 데이터 검증을 위한 테스트 지역

2차 학습지역에 대한 촬영도 동일한 조건으로 촬영을 진행하였다. 2차 학습지역에 대한 이미지는 1차 학습지역에서 촬영고도별 학습한 데이터에

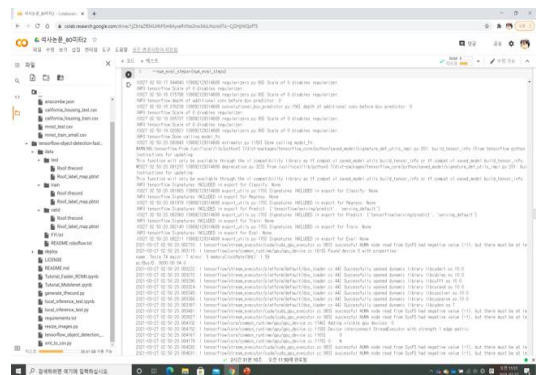
2차 학습지역의 데이터를 추가로 학습시켜 학습데이터의 증감이 결과에 미치는 영향을 알아보고자 하였다. [그림 8]은 2차 학습지역의 추가학습 데이터로 촬영고도 100m에서 촬영된 영상이다.

3.3 학습데이터 검증

학습데이터 검증은 1차 학습지역과 2차 학습지역에서 별도로 테스트 지역을 선정하여 검증하였다. 학습결과에 영향을 미치지 않기 위해 기존 1차, 2차 학습지역과는 다른 별도의 테스트 지역을 선택하였으며 동일한 결과를 얻기 위해 촬영고도는 90미터로 촬영하였다. [그림 8]은 별도의 테스트 지역의 촬영 영상이며, 전체 촬영이미지 229매로 정사영상을 제작하였다. 결과 검증에 필요한 샌드위치패널 건축물의 지붕을 마킹하고 테스트 용도로 사용할 이미지 57매를 선정하였다.

3.4 신경망을 이용한 학습 및 분석

이미지 학습은 1차, 2차 이미지 학습지역의 촬영고도 80미터, 100미터, 150미터의 각각의 영상을 총 6회의 학습으로 진행하였다. 학습은 Faster R-CNN 알고리즘을 이용하였으며, 구글 Colab에서 GPU환경으로 학습하였다.



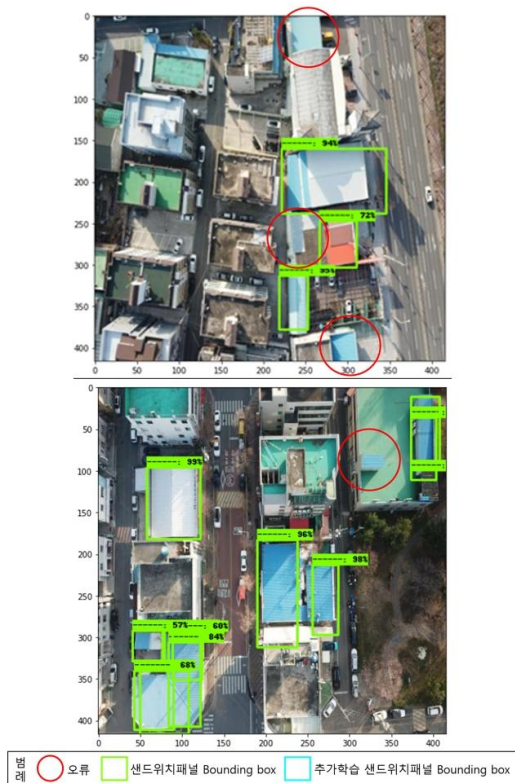
[그림 9] colab 환경에서 이미지 학습

4. 분석 및 평가

4.1 촬영고도별 학습 이미지 분석

4.1.1 촬영고도 80미터

[그림 10]은 1차 학습지역에 대해 촬영고도 80미터에서 촬영한 이미지로 학습한 데이터를 가지고 테스트 지역의 이미지로 결과를 추출한 이미지이다. 붉은색 원으로 표시된 부분이 오류(샌드위치패널 지붕을 탐지하지 못하거나 샌드위치패널 지붕이 아닌 것을 탐지한 경우)로 확인되는 부분이다.

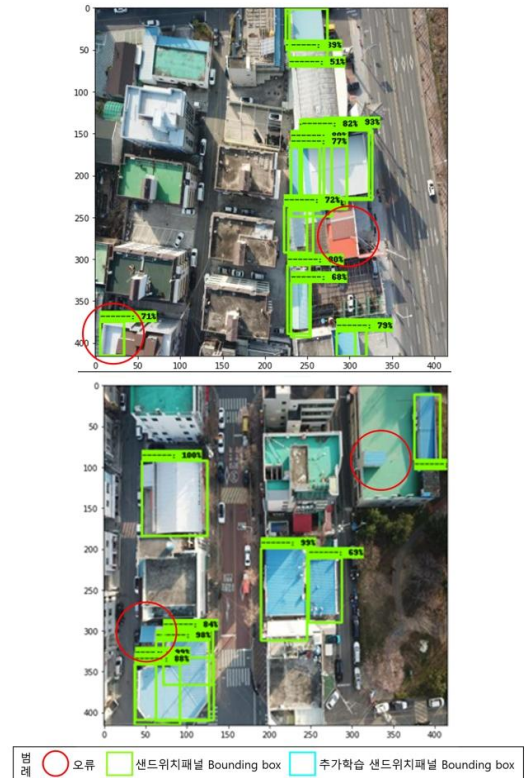


(그림 10) 1차 학습지역(촬영고도 80m)

4.1.2 촬영고도 100미터

[그림 11]은 촬영고도 100미터에서 촬영한 이미지의 1차 학습지역 데이터를 테스트 지역의 이미

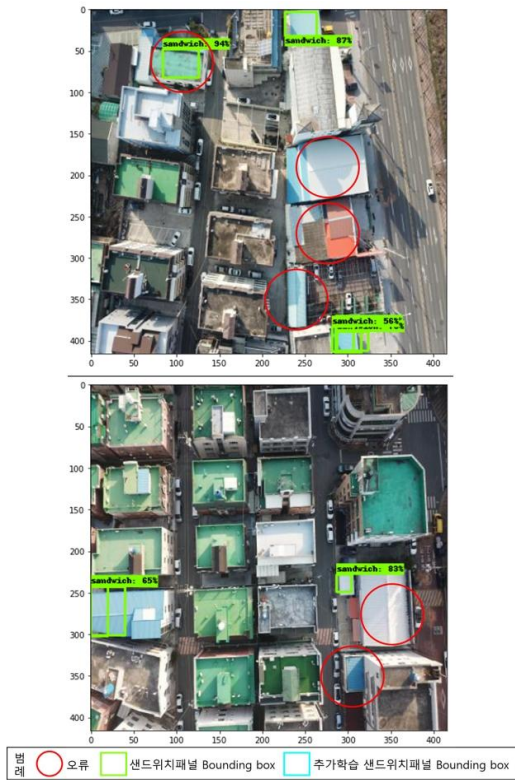
지로 결과를 추출한 영상이다. 붉은색 원으로 표시된 부분이 오류(샌드위치패널 지붕을 탐지하지 못하거나 샌드위치패널 지붕이 아닌 것을 탐지한 경우)로 확인되는 부분이다.



(그림 11) 1차 학습지역(촬영고도 100m)

4.1.3 촬영고도 150미터

[그림 12]는 1차 학습지역에 대해 촬영고도 150미터에서 촬영한 이미지로 학습한 데이터를 테스트 지역의 이미지로 결과를 추출한 영상이다. 촬영고도 150미터에서 촬영한 이미지로 학습한 데이터는 대체로 샌드위치패널의 탐지율이 낮게 나타났다. 또한, 건물 전체가 샌드위치패널인 경우에는 80미터, 100미터 학습데이터에서 고른 탐지율을 보였지만 건축물의 일부분이 샌드위치패널인 경우에는 낮은 고도에서 촬영한 이미지를 학습한 데이터에서 조금 더 높은 탐지율을 보였다.



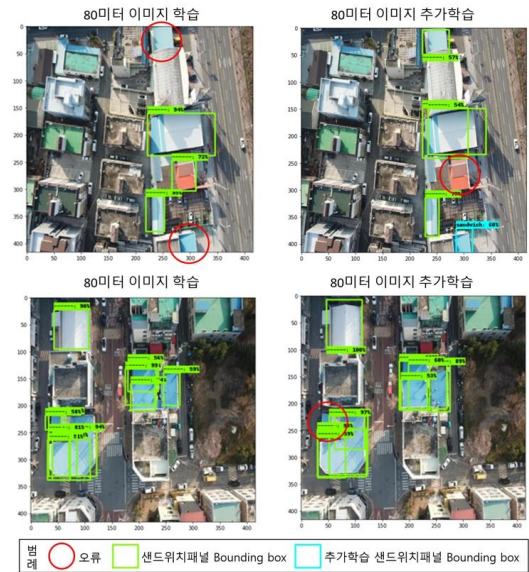
(그림 12) 1차 학습지역(촬영고도 150m)

4.2 촬영고도별 학습 이미지 추가 분석

4.2.1 촬영고도 80미터 추가학습

[그림 13]은 1차 학습구역의 촬영고도 80미터에서 촬영한 이미지와 2차 학습구역의 촬영고도 80미터에서 촬영한 이미지를 같이 학습시킨 테스트 지역의 이미지로 탐지 결과를 추출하였다. 2차 학습구역의 경우 1차 학습구역과 구별하기 위해 학습 시 하늘색 Bounding box를 사용하였다. 붉은색 원으로 표시된 부분이 오류(샌드위치패널 지붕을 탐지하지 못하거나 샌드위치패널 지붕이 아닌 것을 탐지한 경우)로 확인되는 부분이다. 학습데이터를 추가한 경우에도 건물 전체가 샌드위치패널인 경우에는 고른 탐지율을 보였으나, 건축물의 일부가 샌드위치패널인 경우에는 학습을 추가하면서 다소 떨어진 탐지율을 보였다. 하지만 오류율이

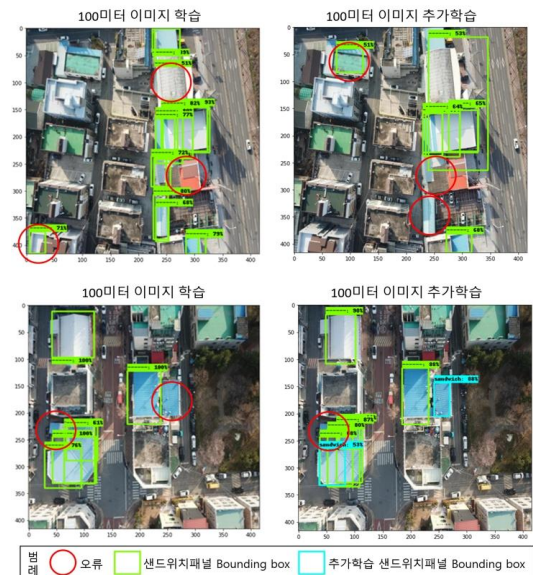
줄어드는 것은 확인할 수 있었다.



(그림 13) 1차 학습지역 추가 학습 결과(80m)

4.2.2 촬영고도 100미터 추가학습

[그림 14]는 1차 학습구역의 촬영고도 100미터에서 촬영한 이미지와 2차 학습구역의 촬영고도



(그림 14) 1차 학습지역 추가 학습 결과(100m)

100미터에서 촬영한 이미지를 같이 학습시킨 결과를 추출하였다. 붉은색 원으로 표시된 부분이 오류(샌드위치패널 지붕을 탐지하지 못하거나 샌드위치패널 지붕이 아닌 것을 탐지한 경우)로 확인되는 부분이다. 촬영고도 80미터의 추가 학습 결과와 동일하게 건물 전체가 샌드위치패널인 경우에는 고른 탐지율을 보였으나, 건축물의 일부가 샌드위치패널인 경우에는 학습을 추가하면서 조금 더 높은 탐지율을 보였다.

4.3 종합적 평가

학습한 데이터에 대한 결과는 테스트지역에 대한 촬영이미지로 검증하였다. 학습시킨 모델의 정확도를 평가하기 위해서 탐지율과 함께 정밀도(Precision)와 재현율(Recall)도 같이 분석하였다.

〈표 2〉 Confusion matrix(혼동 행렬)

		실제 정답	
		True	False
실험 결과	True	True Positive	False Positive
	False	False Negative	True Negative

[출처 : Olson, David L, Delen, Dursun, 2008, pp.138.]

〈표 3〉 모델 Case 의미

구 분	의 미
True Positive(TP)	샌드위치패널 구조인 지붕을 True라고 예측(정답)
False Positive(FP)	샌드위치패널 구조가 아닌 지붕을 True라고 예측(오답)
False Negative(FN)	샌드위치패널 구조인 지붕을 False라고 예측(오답)
True Negative(TN)	샌드위치패널 구조가 아닌 지붕을 False라고 예측(정답)

[출처 : Olson, David L, Delen, Dursun, 2008, pp.138.]

탐지율(Accuracy)이란 맞게 분류한 비율이며, 정밀도(Precision)란 모델이 True라고 분류한 것

중에서 실제 True인 것의 비율이며, 재현율(Recall)이란 실제 True인 것 중에서 모델이 True라고 예측한 것의 비율이다. 재현율과 정밀도는 서로 보완적 지표로 분류의 성능을 평가하는데 적용한다.

탐지율과 정확도, 재현율의 수식은 다음과 같다.

$$Accuracy = (TP + TN) / (TP + TN + FP + FN)$$

$$Precision = \frac{tp}{tp + fp} \quad Recall = \frac{tp}{tp + fn}$$

[출처 : Olson, David, Delen, Dursun, 2008, pp.138.]


테스트 지역의 전체 샌드위치패널 구조의 지붕은 건물전체가 샌드위치패널 구조인 경우가 총 9채, 건축물 중 일부분이 샌드위치패널 구조의 지붕을 가지고 있는 경우는 총 14채, 테스트지역 전체 건물은 126채이다. 이 값을 가지고 결과에 대해 검증하였다. 전체적으로 건물 전체가 샌드위치패널의 구조물인 경우 촬영고도와 관계없이 대부분 탐지가 잘 되었다. 다만 건물의 일부분이 샌드위치패널 구조인 경우에는 저고도(촬영고도 80미터)에서 높은 탐지율을 보였다.

〈표 4〉 탐지 분석 결과

구 분	건물 전체	건물 일부	Miss	Error	탐지율	정확도	재현율
80미터	8	12	3	2	97.6%	90.9%	87.0%
100미터	7	10	6	4	95.1%	81.0%	73.9%
150미터	6	8	9	16	91.8%	46.7%	60.9%
80미터 추가학습	9	11	3	1	97.6%	95.2%	87.0%
100미터 추가학습	8	11	4	2	96.8%	90.5%	82.6%

학습이미지를 추가한 경우 전체 건축물이 샌드위치패널인 경우에는 탐지율에는 큰 차이는 없었다. 하지만 건축물의 일부분이 샌드위치패널 구조인 경우에 80미터는 큰 차이가 없었으나 100미터

는 일부 탐지율이 오른 것을 확인할 수 있었다. 또한 80미터와 100미터 모두 학습데이터를 추가했을 때 Error(샌드위치패널 건축물을 탐지하지 못하는 경우)가 줄어드는 것을 확인할 수 있었다.



(그림 15) 학습 데이터별 결과 분석

본 연구의 결과 고도가 낮은 경우(고해상도 이미지)의 탐지율이 조금 더 높은 것을 확인 할 수 있었으며 학습데이터를 추가한 경우 탐지율이 급격히 올라가는 현상은 없었으나 Error(샌드위치패널 건축물이 아닌 경우 샌드위치패널 건축물로 탐색하는 경우)는 줄어드는 것을 확인할 수 있었다.

5. 결 론

본 연구에서는 촬영한 드론 영상으로부터 학습에 필요한 데이터를 얻기 위해 구축된 데이터 셋을 Faster R-CNN을 활용하여 학습시키고, 테스트 지역의 이미지로 객체를 탐지 및 분석을 시행한 결과 다음과 같은 결론을 얻었다.

첫째, 동일한 작업지역에 대해서 객체탐지는 해상도가 좋으면 탐지율이 높아지는 것을 확인하였다. 80미터에서 촬영한 이미지의 탐지율이 97.6%로 100미터(95.1%), 150미터(91.8%)와 비교해서 가장 높았으며 해상도의 순으로 탐지율이 높은 것

을 확인 할 수 있었다.

둘째, 80미터 추가학습 결과를 보면 탐지율과 재현율은 차이가 없지만 정확도가 90.9%에서 95.2%로 상승하였다.

셋째, 100미터 추가학습의 결과를 보면 탐지율(95.1% → 96.8%), 정확도(81% → 90.5%), 재현율(73.9% → 82.6%) 모두 상승하였다.

두 번째와 세 번째의 결과처럼 추가학습을 통해 정확도와 상승하는 것은 부족한 학습데이터의 다양성을 증가시키면서 훈련데이터의 과적합 없이 일반화 성능을 증가시킨 결과로 어느 정도의 Data Augmentation(데이터 증강)⁴⁾효과를 본 것으로 판단된다.

따라서 본 연구를 통해 객체탐지는 학습데이터의 이미지 해상도와 탐지율은 비례하고 학습데이터량은 정확도와 비례한다는 것을 확인할 수 있었다. 향후에는 이 연구가 실질적으로 건축물들을 분류하는 기법에 활용되어 불법건축물 탐지, 수치지형도의 건물레이어 갱신 등 더 나아가 토지의 불법용도, 건물의 불법용도 탐지 업무에도 활용될 수 있을 것으로 판단된다.

본 연구에서 제시하는 영상취득 및 데이터셋 가공 방법은 실무자가 쉽게 취득 및 가공할 수 있다. 영상취득에 사용한 드론 역시 고가의 드론이 아닌 중급 수준의 드론을 활용하여 충분히 공간정보를 취득할 수 있었으며 만족할 만큼의 결과도 얻었다.

데이터를 가공하는데 필요한 고사양의 하드웨어나 비싼 소프트웨어는 연구하는데 제약이 되었으며 데이터 학습을 위해서 구글 Colab GPU를 이용하였으나 실제 학습시간이 2시간 30분에서 4시간 가까이 학습해야 하는 과정들은 쉬운 과정은 아니었다. 특히 무료로 사용할 수 있는 시간은 12시간으로 하루에 GPU를 사용하는 시간은 제한적이어서 학습데이터를 무한정 늘릴 수도 없었다. 작업지역과 촬영고도, 해상도, 학습 데이터량, 이미지의 조건 등을 변화시켜 비교 검토하여 객체

4) 데이터의 양을 늘리기 위해 원본에 각종 변화를 주어 Input data의 데이터를 확장해 나가는 것.

탐지에 최적의 방법을 찾는 데 다양한 조건을 대입하지 못한 점은 본 연구의 한계로 남았다.

4차 산업혁명을 이끄는 10개의 선도 기술을 기반으로 딥러닝과 드론이 융합의 선도 기술로 포함되어 있다. 그만큼 드론과 딥러닝이 공간정보 산업에도 많은 영향을 미칠 것이다. 향후 AI를 이용한 객체탐지 기술들은 계속적으로 발전해 나아갈 것이다.

〈참고문헌〉

1. 백종환, 김상훈, “실내 드론의 위치 추정을 위한 영상처리 기반 객체 검출”, 「한국정보처리학회 학술대회논문집」, 한국정보처리학회, 제24권 제1호, 2017.
2. 손문범, “샌드위치패널 냉동창고의 화재 확산 원인 및 개선방안에 대한 연구”, 석사학위논문, 서울시립대학교 대학원, 2011.
3. 신창수, “무인항공기 영상을 이용한 건축물 정사영상 부분수정 연구”, 박사학위논문, 서울시립대학교 대학원, 2021.
4. 신현선, 엄정섭, 김준현, “드론영상을 활용한 토석류 발생구간의 피해규모 추적기법”, 「한국측량학회지」, 한국측량학회, Vol.35, No 6, 2017.
5. 안호연·이종택, “실제 도로환경에 적합한 Faster R-CNN 기반 차종분류”, 한국지능시스템학회지, 제28권 제3호
6. 이한솔, “사물 인식을 위한 효율적인 딥러닝 플랫폼”, 「스마트미디어저널」, 한국스마트미디어학회, 제8권, 제2호, 2019.
7. 이유진, “드론으로 획득한 다중분광영상의 정사영상 생성 및 정확도 평가”, 석사학위논문, 충남대학교 대학원, 2020.
8. 장한솔, 고준희, 장화선, “드론으로 취득된 정사영상의 실시간 서비스 시스템 설계 및 구현”, 「대한공간정보학회지」, 대한공간정보학회, 제25권, 제4호, 2017.
9. 함상우, “딥러닝을 이용한 드론 영상 의미론적 분할”, 석사학위논문, 서울시립대학교 대학원, 2019.
10. Olson · David L · Delen · Dursun, “Advanced data mining techniques”, 「Springer」, 2008.
11. Ross Girshick, “Fast R-CNN”, 2015.
12. Shaoqing Ren · Kaiming He · Ross Girshick · Jian Sun, “Faster R-CNN”, 2016.

(접수일 2022.11.03, 심사일 2022.11.18, 심사완료일 2022.11.30.)