

재난지역에서의 신속한 건물 피해 정도 감지를 위한 딥러닝 모델의 정량 평가 Quantitative Evaluations of Deep Learning Models for Rapid Building Damage Detection in Disaster Areas

서준호¹⁾ · 양병윤²⁾

Ser, Junho · Yang, Byungyun

Abstract

This paper is intended to find one of the prevailing deep learning models that are a type of AI (Artificial Intelligence) that helps rapidly detect damaged buildings where disasters occur. The models selected are SSD-512, RetinaNet, and YOLOv3 which are widely used in object detection in recent years. These models are based on one-stage detector networks that are suitable for rapid object detection. These are often used for object detection due to their advantages in structure and high speed but not for damaged building detection in disaster management. In this study, we first trained each of the algorithms on xBD dataset that provides the post-disaster imagery with damage classification labels. Next, the three models are quantitatively evaluated with the mAP (mean Average Precision) and the FPS (Frames Per Second). The mAP of YOLOv3 is recorded at 34.39%, and the FPS reached 46. The mAP of RetinaNet recorded 36.06%, which is 1.67% higher than YOLOv3, but the FPS is one-third of YOLOv3. SSD-512 received significantly lower values than the results of YOLOv3 on two quantitative indicators. In a disaster situation, a rapid and precise investigation of damaged buildings is essential for effective disaster response. Accordingly, it is expected that the results obtained through this study can be effectively used for the rapid response in disaster management.

Keywords : Deep Learning Model, One-Stage Detector, Very High-Resolution Satellite Image, Damaged Detection, Disaster Management

초 록

본 연구는 AI 기법 중에 최근 널리 사용되고 있는 딥러닝 모델들을 비교하여 재난으로 인해 손상된 건물의 신속한 감지에 가장 적합한 모델을 선정하는 데 목적이 있다. 먼저, 신속한 객체감지에 적합한 1단계 기반 검출기 중 주요 딥러닝 모델인 SSD-512, RetinaNet, YOLOv3를 후보 모델로 선정하였다. 이 방법들은 1단계 기반 검출기 방식을 적용한 모델로서 객체 인식 분야에 널리 이용되고 있다. 이 모델들은 객체 인식 처리방식의 구조와 빠른 연산의 장점으로 인해 객체 인식 분야에 널리 사용되고 있으나 재난관리에서의 적용은 초기 단계에 머물러 있다. 본 연구에서는 피해감지에 가장 적합한 모델을 찾기 위해 다음과 같은 과정을 거쳤다. 먼저, 재난에 의한 건물의 피해 정도 감지를 위해 재난에 의해 손상된 건물로 구성된 xBD 데이터셋을 활용하여 초고해상도 위성영상을 훈련시켰다. 다음으로 모델 간의 성능을 비교-평가하기 위하여 모델의 감지 정확도와 이미지 처리속도를 정량적으로 분석하였다. 학습 결과, YOLOv3는 34.39%의 감지 정확도와 초당 46개의 이미지 처리속도를 기록하였다. RetinaNet은 YOLOv3보다 1.67% 높은 36.06%의 감지 정확도를 기록하였으나, 이미지 처리속도는 YOLOv3의 3분의 1에 그쳤다. SSD-512는 두 지표에서 모두 YOLOv3보다 낮은 수치를 보였다. 대규모 재난에 의해 발생한 피해 정보에 대한 신속하고 정밀한 수집은 재난 대응에 필수적이다. 따라서 본 연구를 통해 얻은 결과는 신속한 지리정보 취득이 요구되는 재난관리에 효과적으로 활용될 수 있을 것이라 기대한다.

핵심어 : 딥러닝 모델, 1단계 기반 검출기, 초고해상도 위성영상, 피해감지, 재난관리

Received 2022. 07. 20, Revised 2022. 08. 08, Accepted 2022. 09. 13

1) Dept. of Geography, M.S. Student, Dongguk University (E-mail: seojho2075@dgu.ac.kr)

2) Corresponding Author, Member, Associate Professor, Dept. of Geography Education, Dongguk University (E-mail: yby94@dgu.ac.kr)

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

1. 서론

1.1 연구 배경 및 목적

전 세계적으로 발생하고 있는 대규모의 자연재해는 커다란 재산피해와 더불어 인간의 삶의 터전을 무너트리는 매우 위협적인 요소로 간주되고 있다. 따라서 재난이 발생한 직후 피해를 입은 지역에 대한 신속한 복구 노력은 인간의 생존권을 지켜줄 수 있는 매우 중요한 일이 되고 있다. 재난이 발생한 지역에 대한 신속한 대응을 위해서는 재난이 발생한 지역에서의 다양한 지리정보 취득과 재난 관련 공간DB의 구축이 필수적으로 요구된다(Yang and Jahan, 2018). 일반적으로 재난이 발생한 지역의 지리자료 취득을 위해서는 현장을 방문하여 피해 현황을 직접 조사하거나 설문조사 방법을 통해 피해의 정도를 파악하는 방법이 있다. 그러나 현장조사는 많은 시간과 인력을 요구하며 대형 자연재해의 경우 재난 발생지역에 대한 접근이 불가능하여 지리자료 및 공간정보를 취득하는 데 한계를 가지고 있다. 즉, 현장조사를 통한 공간 DB(Database)의 구축은 시간, 인력, 접근 불가능 등의 한계로 인해 신속한 복구를 위한 1차 자료 수집에 어려움을 지닌다. 이러한 이유로 접근이 불가능한 지역과 광범위한 피해지역에 대한 신속한 지리자료의 구축을 위해서는 원격탐사 기법의 활용이 필수적으로 요구된다(Jha et al., 2008). 특히, 재난지역에 대한 원격탐사 자료는 피해 규모를 파악할 수 있게 하는 중요한 자료로 활용된다. 원격으로 탐측된 영상에서 추출할 수 있는 정보로는 재난피해 면적 파악, 재난 발생 직후의 인명구조, 자원 배치를 위한 정책 결정 등으로 이 자료들은 재난 복구의 여러 단계에서 널리 활용되고 있다(Pesaresi et al., 2007). 최근에는 무인 항공기를 활용한 고해상도 위성영상의 취득이 원활해졌으나 여전히 광범위한 지역에 대한 신속한 지리자료 취득에는 한계를 가지 있다(Tatham, 2009; Clark et al., 2018). 이러한 배경에서 위성영상은 홍수, 산불, 지진 등의 자연재해에 대해 신속하고 광범위한 모니터링이 가능하다는 이점을 지녀 재난 대응 및 복구 과정에서 그 활용에 대한 수요가 지속적으로 증가하고 있다(Joyce et al., 2009; Ghaffarian et al., 2019).

과거 위성을 통해 중·저해상도의 품질을 갖는 위성영상 취득이 주를 이루었으나 최근 고해상도 영상을 취득할 수 있는 센서의 발달로 인해 높은 공간해상도를 갖는 위성영상의 수집과 구축이 가능해졌다. 그러나 아직까지 고해상도 위성영상을 활용하는 재난 피해조사 연구는 초기 단계에 머물러 있다(Jang et al., 2019; Lee et al., 2019; Kim et al., 2020). 높은 공간해상도와 넓은 촬영 범위를 특징으로 하는 중·저해상도 위

성영상은 재난으로 인해 피해를 입은 지역의 면적을 파악하는 데 효과적이지만, 낮은 공간해상도로 인해 세밀한 지리객체의 감지에는 어려움이 있다. 특히, 건물 단위의 정밀한 재난 피해조사를 위해서는 1m 미만의 공간해상도를 가지는 초고해상도 위성영상의 활용이 필수적이다. 하지만 초고해상도 위성영상은 조밀하고 세밀한 객체를 다수 포함하고 있어 영상분류작업에 많은 시간이 소요되며 높은 정확도의 분류 결과를 얻는 데 한계가 있다(Deng and Yu, 2014; Gang et al., 2016).

최근에는 초고해상도 위성영상을 활용한 영상분류결과의 정확도를 향상시키기 위해 머신러닝이나 딥러닝 과 같은 인공지능(AI: Artificial Intelligence) 방법론을 적용한 연구가 활발히 이루어지고 있다. 특히 건물 손상 정도 탐지 분야에서는 딥러닝 모델의 네트워크 구조를 개선하여 탐지 정확도를 올리는 연구가 중점적으로 수행되고 있다(Bowman et al., 2021; Ding et al., 2022). 하지만 기존 연구들은 모델의 이미지 처리 속도를 고려하지 않은 경우가 대부분이며, 또한, 어떠한 딥러닝 모델이 건물의 손상 정도를 탐지하는 데 효과적인지에 대한 연구는 부족한 상황이다. 이와 같은 관련 연구의 부재에 따라 국토지리정보원에서 관리하는 긴급공간정보처럼 단기간에 신속하게 건물의 피해 정보를 탐지하는 방법에 관한 연구나 이와 관련된 결과물에 대한 데이터는 제공되지 않고 있다.

이러한 배경에서 본 연구는 주요 딥러닝 모델 중 초고해상도 위성영상을 활용한 신속한 건물 피해감지에 가장 적합한 모델을 선정하는 데 목적이 있다. 이를 달성하기 위해 다음과 같은 세부 목표를 갖는다. 첫째, 본 연구에서는 재난 피해지역의 건물 피해 정도를 구분하여 감지하기 위해 오픈소스 데이터셋인 xBD를 활용하여 딥러닝 모델의 학습을 수행한다. xBD 데이터셋은 초고해상도 위성영상으로 제작된 데이터셋으로, 재난에 의한 건물 피해 정도가 4단계로 구분되어 구축되었다(Gupta et al., 2019). 둘째, 딥러닝 모델의 성능을 정량적으로 평가하기 위하여 감지 정확도와 이미지 처리속도를 계산한다. 감지 정확도의 측정을 위해서 딥러닝 모델의 객체감지 성능 평가에 활용되고 있는 mAP(mean Average Precision)을 정량지표로 이용한다. 이미지 처리속도에 관해서는 딥러닝 모델이 초당 처리할 수 있는 이미지 수(FPS: Frame Per Second)를 측정하여 평가지표로 활용한다. 마지막으로 산출된 두 지표를 동시에 고려하여 재난관리 작업의 대응 단계에서 효과적으로 활용할 수 있는 최적 딥러닝 모델을 선정한다.

1.2 문헌 검토

Baker (1989)에 따르면 원격탐사 기술을 활용한 최초의 체계적 재난 피해평가 연구는 1906년에 이루어졌다. 일리노이

의 사진작가인 George R. Lawrence는 지진 피해를 받은 샌프란시스코의 일부 지역에 대해 카메라를 장착한 연을 활용하여 자료를 수집하였다. 이후 지속적으로 다양한 재난관리 연구가 이루어지면서 지리정보의 신속한 취득에 대한 필요성이 점차 주목받게 되었다(Johnson, 1994; Yamazaki *et al.*, 2004). 특히, 재난에 의해 발생한 건물의 피해 정도는 재난지역 피해 규모 파악, 피해 유형 구분 등에 활용되는 필수적인 정보이다. 피해 정도 감지에 활용되는 자료에는 고해상도의 광학 영상과 SAR(Synthetic Aperture Radar), LiDAR(Light Detection and Ranging)가 있다. 특히 센티미터 수준의 공간 해상도를 가진 고해상도 광학 영상은 피해조사에서 높은 활용성을 가지며, 여러 플랫폼으로부터 취득할 수 있다는 이점으로 인해 교통망의 손상 파악, 범람에 의한 해안선의 변화 분석 등의 다양한 연구에서 활발히 사용되었다(Li *et al.*, 2011; Yang, 2016).

고해상도 위성영상은 홍수, 산불, 지진 등의 자연재해에 대해 신속하고 광범위한 모니터링이 가능하다는 점에서 무인 및 유인 항공기에 비해 강점을 지녀 다양한 재난 상황에서 활발히 활용되고 있다. 2011년 3월, 후쿠시마 지역의 쓰나미는 약 26,000명의 사상자와 최대 47만명의 이재민을 발생시켰다. 이에 일본 당국에서는 재난 발생 직후부터 IKONOS, GeoEye-1 등의 고해상도 위성영상을 통해 재난 발생 전/후의 이미지를 분석하고, 해안선의 변화나 시설물의 파괴 및 수물 현황을 파악하였다. 해당 사례는 2004년 니가타 지역의 지진이나 2006년 수마트라 지역의 쓰나미 사태와는 달리 고해상도 위성영상이 신속한 재난피해 파악에 효과적으로 활용되었다고 평가받는다(RSSJ, 2011). 2015년 4월에는 네팔 고르카 지역에서 발생한 지진은 모멘트 규모 7.8의 지진이 약 24,000명의 사상자를 발생시켰다. 지진 발생 직후, 세계 각국에서는 인도적 지원을 위해 다양한 방향에서 재난지역의 정보를 취득하여 분석하고자 하였다. 특히, 지진 후 산사태나 여진 등의 위험이 남아 현장에서의 정보 수집에 어려움을 겪는 상황에서 고해상도 위성영상은 건물의 붕괴 정도, 이재민 대피장소 파악 등의 재난 대응 작업에 사용되며 재난관리에 필요한 정보를 수집할 수 있음이 확인되었다(Kim *et al.*, 2017). 하지만 이러한 활용에도 불구하고 여전히 대용량의 고해상도 위성영상은 신속한 객체의 탐지에 한계를 보였다(Gang *et al.*, 2016). 고해상도 위성영상에서 픽셀의 분광정보를 이용할 뿐만 아니라 객체를 기본 단위로 하여 분류를 수행하는 지리객체 기반 영상 분석 방법(GEOBIA: Geographic-Based Image Analysis)이 논의되었지만, 인간 중심의 스케일 최적화라는 점에서 넓은 지역에는 비실용적이라는 지적

을 받았다(Ma *et al.*, 2017).

최근에는 이미지에서 객체를 정확하게 인식하기 위해 AI 방법론 중 CNN(Convolution Neural Network)을 기반으로 하는 딥러닝 기술 연구가 활발히 이루어지고 있다. 초기 이미지 분류 딥러닝 모델은 객체의 위치를 탐지하지 못하는 한계를 보였다. 해당 문제점을 해결하기 위해 Selective search 및 RoI(Region of Interest) 등 다양한 방식을 활용하는 모델이 개발되었다(Girshick *et al.*, 2015). 이러한 모델들은 객체의 영역 추정과 분류 작업을 2단계에 걸쳐 수행한다는 특징이 있는데, 이와 같은 방식은 2단계 기반 검출기(Two-Stage Detector)로 분류된다. 한편으로는 더 빠른 감지를 위해 기존의 2단계 기반 검출기와 달리 단일 네트워크상에서 영역 추정과 클래스 점수를 함께 예측하는 1단계 기반 검출기(One-Stage Detector)가 제시되었다. Redmon *et al.* (2016)은 영역 추정과 조건부 클래스 확률(Class Confidence Score)을 단일 네트워크에서 수행하는 YOLO(You Only Look Once) 알고리즘을 제시하였다. YOLOv1은 Pascal VOC 2007에 대해 초당 45프레임의 처리속도와 63.4%의 mAP를 기록하였다. YOLOv1의 알고리즘은 감지 속도를 개선하는 데 효과적이었지만 다양한 크기의 객체를 인식하는 정확도 측면에서는 2단계 기반 검출기에 비해 저조한 성능을 보였고, SSD(Liu *et al.*, 2016), RetinaNet(Lin *et al.*, 2017) 등의 새로운 모델들이 더 빠른 이미지 처리속도와 높은 정확도를 목표로 제시되었다. Carranza-García *et al.*(2020)는 MS COCO 데이터셋에 대한 테스트를 수행하여 1단계 기반 검출기인 YOLOv3나 RetinaNet이 대표적인 2단계 기반 검출기인 Faster R-CNN에 비해 평균적으로 10% 낮은 mAP를 보이지만, 이미지 처리속도는 최대 3배까지 빠르게 기록되는 것을 확인하였다. 이러한 1단계 기반 검출기는 빠른 이미지 처리속도를 바탕으로 상태 감지, 해양 쓰레기 탐지 등 긴급하게 이미지 처리가 필요한 분야에서 널리 활용되고 있다(Alfarrarjeh *et al.*, 2018; Xue *et al.*, 2021).

원격탐사를 활용한 재난관리 영역에서도 대용량의 고해상도 영상을 효과적으로 처리하기 위해 CNN 기반의 딥러닝 모델을 활용한 연구가 활발히 진행되고 있다. Ji *et al.* (2018)은 딥러닝 모델을 사용하여 2010년 아이티 지역의 지진에 대해 무너진 건물과 무너지지 않은 건물을 구분하는 연구를 수행하였다. 해당 연구에서 연구팀은 재난지역에서 손상된 건물과 손상되지 않은 건물의 수가 불균형하다는 사실을 밝히고, 3가지 균형 조정 방식을 적용해 cost-sensitive 방식이 가장 높은 성능을 가진다는 결과를 도출하였다. Ding *et al.*(2022)은 Faster R-CNN 모델을 바탕으로 IPO(Intersected

Proportion of Objects) 방식과 개선된 NMS(Non-Maximum Suppression) 방식을 적용하여 원격탐사 영상에서 지진으로 인해 손상된 건물을 탐색하는데 성능 개선을 이루었다. 이처럼 딥러닝 모델 기반의 재난 피해평가 연구는 네트워크 개선부터 응용 분야까지 다양하게 수행되고 있지만, 건물 피해평가에 가장 적합한 모델을 선정하는 연구는 미비한 실정이다. 특히 신속한 자료 취득은 효과적인 재난 대응에 필수적임에도 불구하고, 기존의 모델 비교 연구는 대부분 감지 정확도만을 고려하고 있다(Xu *et al.*, 2019; Kalantar *et al.*, 2020). 또한, 재난 대응 단계에서 활용하기에 적합한 1단계 기반 검출기를 선정하는 연구 역시 이루어지지 않았다. 재난 대응은 다른 재난관리 단계와 비교해 신속성의 중요도가 가장 크기 때문에 2단계 기반 검출기에 비해 빠른 이미지 처리속도를 지닌 1단계 기반 검출기의 활용에 관한 연구가 필요하다.

이러한 배경에서 본 연구는 초고해상도 위성영상에서 건물 피해 정보를 신속히 감지하는 데 가장 적합한 딥러닝 모델을 선정하고자 한다. 이를 위해 주요 1단계 기반 검출기로 알려진(Zou *et al.*, 2019) SSD-512, RetinaNet, YOLOv3의 감지 정확도와 이미지 처리속도에 대한 정량지표를 계산하고, 두 정량지표를 바탕으로 비교·평가하였다.

2. 연구 설계 및 방법론

2.1 연구 흐름

Fig. 1은 본 연구의 흐름을 모식화 한 것이며, 연구는 총 3단계로 나누어서 진행된다.

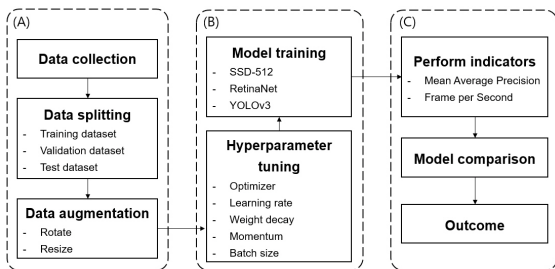


Fig. 1. Workflow of the research: (A) Phase 1; (B) Phase 2; (C) Phase 3

연구의 1단계는 데이터 수집과 전처리 과정이다. xBD 데이터셋은 하나의 파일로 구성되어 있기 때문에 학습과 검증, 평가에 활용할 수 있도록 6:2:2의 비율로 분할하였다. 또한, xBD

데이터셋의 불균형에 의한 영향을 감소시키기 위해 학습 데이터셋에 대해 데이터 증강 작업을 수행하였다. 데이터 증강 작업은 불균형한 데이터셋이 딥러닝 모델 학습에 미치는 부정적 영향을 줄이고, 보다 견고한 결과 도출을 위해 수행하는 작업이다(Perez and Wang, 2017). 2단계는 전처리 과정을 거친 데이터셋에 맞춰 하이퍼 파라미터를 조정하여 3개의 딥러닝 모델을 학습시키는 단계이다. 연구의 3단계에서는 모델 비교평가에 활용하는 2가지 지표를 도출하고, 도출한 정확도 평가 지표와 이미지 처리속도를 비교하였다. 최종적으로는 두 평가지표를 동시에 고려하여 효율적인 재난관리를 지원하는데 가장 적절한 모델이 무엇인지를 결정하였다.

2.2 연구 모델

본 연구에서는 대표적인 1단계 기반 검출기로 알려진 SSD-512, RetinaNet, YOLOv3 딥러닝 모델을 사용하며, 테스트 데이터셋에 대한 각 모델의 mAP, FPS를 측정하여 비교한다. 이를 통해 재난 상황에서 어떠한 모델이 신속하고 정확하게 손상된 건물을 인지할 수 있는지를 평가한다.

2.2.1 SSD-512

SSD(Single Shot Detector)는 이미지 내 객체를 신속하게 감지하기 위해 제안된 1단계 기반 검출기 방식을 적용한다(Liu *et al.*, 2016). SSD의 백본은 모델에 맞춰 수정된 VGG-16이 사용되었고, 학습에는 ILSVRC CLS-LOC 데이터셋이 활용되었다. SSD는 일반적으로 영역 추정 단계에서 수행하는 슬라이딩 윈도우나 RPN(Region Proposal Network) 단계를 거치지 않고, 단일 이미지에서 객체를 감지할 수 있도록 multi-scale feature maps를 적용하였다. Multi-scale feature maps이란 모델이 객체를 예측하는 작업을 여러 크기의 feature map에서 수행하는 것을 의미한다. SSD는 multi-scale feature map 방식을 적용해 원본 이미지에 대한 변형 없이 다양한 크기의 객체를 신속히 감지할 수 있다. SSD는 비슷한 시기에 개발된 1단계 기반 검출기인 YOLOv1에 비해 우수한 이미지 처리속도와 감지 성능을 보여준 방법이다(Liu *et al.*, 2016).

2.2.2 RetinaNet

RetinaNet은 기존의 1단계 기반 검출기 모델들이 가진 class imbalance 문제를 해결하고 2단계 기반 검출기 수준의 감지 성능을 달성하기 위해 제안된 딥러닝 모델이다(Lin *et al.*, 2017). Class imbalance는 객체감지를 수행할 이미지의 객체 영역(positive sample)이 배경 영역(negative sample)

에 비해 과도하게 작은 경우 딥러닝 모델에 부정적 영향을 끼치는 문제를 의미한다. 이에 RetinaNet은 class imbalance 문제를 해결하기 위해 focal loss를 모델에 적용하였다. Focal loss는 배경 영역에 대한 가중치를 낮추고 객체 영역에 집중하는 방식으로 쉽게 분류되는 대다수의 배경 영역에 모델 학습이 치우치는 것을 완화한다. 또한, RetinaNet은 다양한 스케일의 객체를 감지하기 위하여 ResNet 기반의 FPN(Feature Pyramid Network) 구조를 적용한다. FPN 구조는 다양한 스케일의 feature map을 생성하고, 각 feature map의 해상도에서 확인할 수 있는 특징을 추출해 객체를 감지하는 방법이다. RetinaNet은 상기 방법들의 적용을 통해 2단계 기반 검출기를 포함한 다른 딥러닝 모델들과 비교해 우수한 객체감지 성능을 기록하였다(Lin *et al.*, 2017).

2.2.3 YOLOv3

YOLOv3는 Darknet-53을 백본으로 한 1단계 기반 검출기 방식을 적용한 객체감지 모델이다(Redmon *et al.*, 2018). Darknet-53은 YOLOv2에서 백본으로 사용된 Darknet-19의 개선된 버전으로, 보다 정확하고 신속한 객체 감지를 위해 설계된 네트워크 구조를 가진다. 또한 YOLOv3는 다양한 스케일의 객체를 감지하고자 FPN과 유사한 방식으로 multi-scale feature map을 생성한다. Darknet-53을 바탕으로 3개의 다른 크기의 feature map을 생성하고, 2개의 작은 feature map에 업샘플링(upsampling)을 수행한다. 이러한 구조를 바탕으로 YOLOv3는 각 feature map으로부터 객체의 영역 추정과 분류에 필요한 정보를 획득할 수 있다. YOLOv3는 영역 예측 단계에서도 3개의 스케일의 feature map을 활용하여 각 feature map마다 3개의 앵커 박스(anchor box)를 생성해 총 9개의 앵커 박스를 얻었다. 이는 5개의 앵커 박스를 바탕으로 객체의 위치를 예측하는 YOLOv2에 비해 더 정확한 예측을 가능하게 하였다. YOLOv3는 이러한 방식의 적용을 통해 비슷한 시기에 사용되던 1단계 기반 검출기와 유사한 성능을 유지하면서도 기존 모델들에 비해 3배 가까이 빠른 이미지 처리속도를 기록하였다(Redmon *et al.*, 2018).

2.3 평가지표

2.3.1 정확도 평가

모델의 감지 정확도를 평가하기 위해 혼동행렬(Confusion Matrix)을 바탕으로 한 정량지표를 도출한다. 우선, 혼동행렬을 객체감지 정확도 평가에 적용하기 위해서 정확한 예측에 대한 정의가 필요하다. 본 연구에서는 모델의 객체감지 성능에 대한 평가 척도로 IoU(Intersection over Union)를 사용하

였다. IoU란 예측한 바운딩 박스(bounding box)와 미리 설정한 ground truth bounding box가 얼마나 일치하는지 정량적으로 파악할 수 있는 지표로, 두 바운딩 박스의 교집합을 합집합의 면적으로 나눈 값이다. 따라서 두 바운딩 박스가 일치할수록 1에 가까운 값이 계산되고, 이를 통해 객체감지 모델이 얼마나 객체를 잘 감지하였는지를 평가할 수 있다. 모델이 객체의 중심 좌표와 크기를 허용 IoU보다 높게 예측하는 경우 TP(True Positive)로 분류할 수 있다. 객체의 클래스를 잘못 인식하거나, 허용 IoU보다 낮게 예측한다면 FP(False Positive)로 분류한다. 실제 객체가 있는 영역을 인식하지 못하면 FN(False Negative)으로 분류한다. 손상된 건물의 부재를 인식하지는 않기 때문에 TN(True Negative)은 분류하지 않는다.

모델의 성능을 측정하기 위한 기본적인 지표로는 Precision과 Recall이 사용된다. Precision과 Recall은 혼동행렬을 통해 도출된 4가지 분류(TP, FP, FN, TN)를 바탕으로 Eq. (1)과 Eq. (2)와 같이 계산된다.

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

Precision은 Positive로 예측된 객체 중 실제 Positive인 객체의 비율을 의미한다. 반면 Recall은 실제로 Positive인 객체 중 Positive로 예측된 것의 비율을 의미한다. 해당 지표를 바탕으로 AP(Average Precision)와 mAP를 계산하였다.

AP와 mAP은 컴퓨터비전 영역에서 모델의 객체 인식 성능을 정량적으로 나타내기 위해 활용되는 대표적인 지표이다(Lin *et al.*, 2016; Lin *et al.*, 2017). AP는 Precision-Recall Curve의 면적을 계산한 값으로, 일반적인 Precision-Recall Curve는 지그재그 형태의 곡선이기 때문에 불규칙한 곡선 형태를 제거하기 위해 보간법을 사용해야 한다. 본 연구에서는 all-point interpolation을 사용하여 AP를 계산하였다. All-point interpolation은 모든 recall level에서 해당 Recall에 대한 Precision을 사용하는 대신 해당 Recall보다 큰 recall level의 최대 Precision(P_{interp})을 기준으로 그래프를 재구성하는 방법이다. 이후 AP를 구하기 위해 재구성된 그래프의 AUC(Area Under Curve)를 계산한다. AP의 계산 과정은 Eq. (3)과 Eq. (4)를 따른다.

$$AP_{all} = \sum_n (R_{n+1} - R_n) P_{interp}(R_{n+1}) \quad (3)$$

$$P_{interp}(R_{n+1}) = \max_{\tilde{R}: R \geq R_{n+1}} P(\tilde{R}) \quad (4)$$

mAP는 테스트 데이터셋 전체에 대한 AP의 평균값으로, 데이터셋 내부의 전체 데이터에 대한 모든 클래스의 평균 AP이다. mAP는 Eq. (5)에 의해 계산된다. N은 총 클래스의 수이고, AP_i는 i번째 클래스의 AP 값이다.

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (5)$$

2.3.2 이미지 처리속도 평가

FPS는 딥러닝 모델이 초당 처리할 수 있는 이미지의 수를 의미한다. 일반적으로 FPS가 25보다 크게 측정되면 해당 모델이 긴급하게 이미지를 처리할 때 유용하다고 판단될 수 있다(Yang et al., 2021). 본 연구에서는 모델의 객체 인식 속도를 측정하는 지표로 FPS를 채택하고, 이미지 처리속도가 빠를수록 재난 대응 작업에 적합하다고 판단하였다.

2.4 학습 데이터셋

최근에는 많은 딥러닝 기반 연구에서 객체감지 모델의 성능을 보다 상승시키기 위해 대규모의 오픈소스 데이터셋을 사용한다(Groener et al., 2019; Van Etten et al., 2021). 현재의 대다수 딥러닝 모델은 데이터 기반으로 학습이 수행되고, 학습 데이터셋의 크기는 딥러닝 모델의 성능에 매우 직접적인 영향을 끼친다. 그러나 정확하고 방대한 규모의 데이터셋을 제작하는 작업에는 여러 어려움이 수반되고, 특히 큰 데이터 크기를 가지는 항공사진이나 위성영상으로 데이터셋을 제작하는 작업은 데이터 수집부터 처리하는 전 과정에서 많은 인력과 시간을 소모시킨다.

본 연구에서는 개인 데이터셋의 문제를 극복하기 위해 xView2 AI challenge에서 제공하는 xBD 데이터셋을 활용하였다. xBD는 45,000km²에 걸쳐 6가지 유형의 재난(지진, 쓰나미, 홍수, 화산 폭발, 산불, 허리케인)에 대한 850,000개 이상의 건물 객체를 포함하는 대규모 데이터셋이다. xBD 데이터셋에 있는 건물 객체는 EMS(European Macroseismic Scale)-98을 기반으로 한 JDS(Joint Damage Scale) 분류에 따라 지역의 재난에 건물이 얼마나 손상되었는지에 대해 4단계(No-damage, Minor-damage, Major-damage,

Destroyed)로 구분된다. 학습에는 0.55m의 공간해상도를 가진 위성영상 5,198장이 사용되었으며, 모든 이미지는 동일한 지역에 대한 재난 전·후의 이미지로 구성되었다(Gupta et al., 2019).

2.5 학습 환경 및 하이퍼 파라미터

본 연구는 Google Colaboratory(이하 Colab) 환경에서 수행되었다. Colab은 Google社에서 제공하는 클라우드 기반의 통합 개발 환경(Integrated Development Environment, IDE)으로 추가적인 설정 없이 브라우저에서 활용 가능한 Jupyter notebook 환경을 제공한다. 대용량 데이터셋에 대한 학습은 Colab에서 제공하는 딥러닝 학습용 고성능 GPU인 Tesla-T4를 통해 이루어졌다. 연구에서 사용된 모델은 모두 Python 프로그래밍 언어와 Pytorch 프레임워크 기반으로 구축되었으며, MS COCO 데이터셋에 대해 사전학습 과정을 거쳤다.

본 연구에서는 각 모델이 최적의 성능을 갖도록 각 모델에 적합한 하이퍼 파라미터를 적용하였으며, 그 내용은 Table 1과 같다.

Table 1. Hyper parameter configuration

Parameter	SSD-512	RetinaNet	YOLOv3
Optimizer	Stochastic Gradient Descent with Momentum		
Learning rate	0.01	0.001	0.001
Momentum	0.9	0.9	0.9
Weight decay	0.0001	0.0005	0.0005
Batch size	16	16	16

각 모델의 하이퍼 파라미터는 모델이 처음 활용된 원논문에서 제시한 값을 적용하였고(Liu et al., 2016; Lin et al., 2017; Redmon et al., 2018), 개별 값에 대해 튜닝 과정을 거쳐 가장 높은 감지 정확도를 도출한 값을 적용하였다. 배치 사이즈(batch size)는 데이터셋과 학습 환경에 맞춰 조정하였다. 학습은 총 100회 수행되었고, 가장 마지막에 학습된 모델에 대해 평가를 수행하였다.

3. 실험 결과

모델 학습이 끝난 후, 모델의 성능 평가를 위해 mAP를 도출하였다. 결과는 Table 2와 같다

Table 2. Quantitative evaluation for damage detection

Model	Precision	Recall	mAP	Training time
SSD-512	36.1%	45.14%	31.99%	360 min
RetinaNet	41.15%	46.98%	36.06%	1,020 min
YOLOv3	43.15%	43.05%	34.39%	480 min

총 100 에포크(epoch)의 학습을 통해 RetinaNet은 36.06%로 SSD-512, YOLOv3와 비교해 각각 1.67%, 4.07% 더 높은 mAP를 기록하였다. 세부적으로는 전체 건물에 대해 얼마나 많은 건물을 옳게 탐지했는지 평가하는 Recall과 탐지한 결과가 실제 건물과 비교하여 얼마나 일치하는지 평가하는 Precision이 각 모델에서 어떻게 기록되었는지에 대해 살펴볼 수 있다. SSD-512의 Recall은 45.14%로 다른 두 모델에 비해 실제 옳게 검출된 결과물 중 옳다고 예측한 것의 비율은 낮지 않으나, 검출 결과 중 옳게 검출한 비율을 의미하는 Precision이 크게 낮아 전반적인 성능인 mAP가 낮게 산출되었다. RetinaNet은 전체 모델 중 가장 높은 Recall을 기록하면서 Precision 역시 가장 우수한 YOLOv3에 비해 단 2%만 차이를 보여 결과적으로 가장 높은 mAP를 기록하였다. YOLOv3는 가장 낮은 Recall을 기록하였으나, SSD-512보다 7% 높은 Precision을 기록하여 중간 수준의 mAP를 얻었다. 학습시간에서는 RetinaNet은 100 에포크의 학습에 약 1,020분이 필요하였지만, SSD-512는 약 360분, YOLOv3는 약 480분이 필요로 하였다.

Fig. 2는 피해감지 결과의 예시로, 동일한 지역에 대한 각 모델의 감지 결과를 시각화한 것이다. Ground truth와 각 모델의 감지 결과물을 비교하면 SSD-512는 감지에 실패한 건물이 4개, Major-damage나 Destroyed를 No-damage로 잘못 분류한 결과가 3개 확인되었다. RetinaNet은 감지에 실패한 건물이 2개, Major-damage를 Destroyed로 잘못 분류한 결과가 2개 확인되었다. 마지막으로 YOLOv3는 감지에 실패한 건물이 1개, Major-damage나 Destroyed를 No-damage로 잘못 분류한 결과가 2개 확인되었다. YOLOv3는 오분류 결과의 개수가 RetinaNet과 같은 2개로 나타나지만, RetinaNet과 달리 피해 사실 자체를 No-damage로 감지하지 못했다는 점에서 RetinaNet과 정확도 측면에 차이가 있다. 결과적으로 RetinaNet이 YOLOv3와 SSD-512에 비해 전반적으로 우수한 감지 성능을 보인다는 것을 확인할 수 있다.

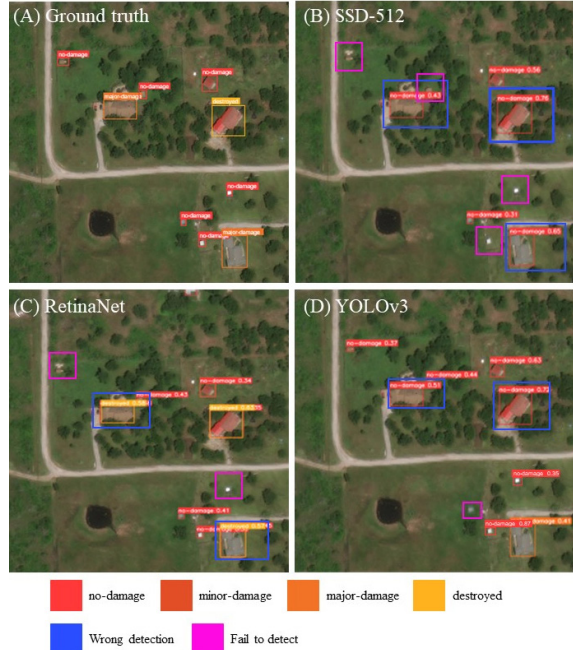


Fig. 2. Results of damage detection: (A) Ground truth; (B) SSD-512; (C) RetinaNet; (D) YOLOv3

Fig. 3은 FPS와 mAP에 대한 결과를 종합적으로 보여주고 있다.

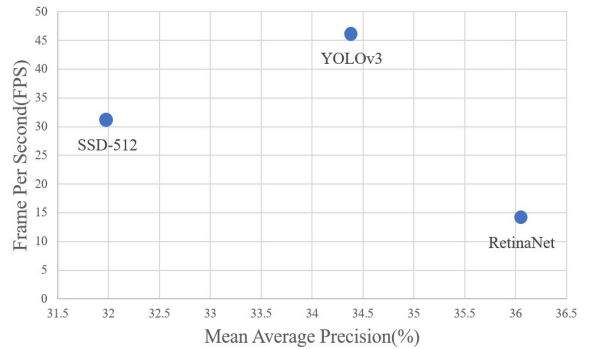


Fig. 3. mAP-FPS Chart

그림의 X축은 딥러닝 모델의 감지 정확도 평가지표인 mAP를, Y축은 이미지 처리속도 평가지표인 FPS를 의미한다. 이미지 처리속도 측면에서는 YOLOv3가 초당 46개의 이미지를 처리하였고, SSD-512는 초당 31개의 이미지를 처리하였다. YOLOv3가 SSD-512보다 더 높은 FPS를 기록하였지만, 두 모델 전부 실시간 이미지 처리 기준인 25 FPS를 초과한다. 반면

RetinaNet은 세 모델 중 가장 우수한 감지 성능을 보였지만, 이미지 처리속도는 초당 14개로 다른 두 모델에 비해 이미지 처리속도가 느리다는 점을 확인하였다. 이를 통해 YOLOv3가 재난 후 지역에 대한 신속한 피해평가에서 가장 우수한 효율성을 가진다는 것을 확인할 수 있었다.

YOLOv3는 재난지역의 대부분 건물에 대해 감지를 성공적으로 수행하였지만, 특정 상황에서는 건물의 감지에 실패하거나 건물의 피해 정도를 잘못 분류하는 등의 한계 역시 발견되었다. Fig. 4와 Fig. 5는 모델의 학습에 활용되지 않은 재난에 대한 YOLOv3의 감지 및 분류의 실패 사례이다.




Fig. 4. An example of failure cases for small sample detection: (A) Ground truth; (B) Prediction

Fig. 4는 YOLOv3 모델이 작은 건물에 피해감지를 실패한 사례를 보여준다. Fig. 4(A)의 Ground truth를 살펴보면 파괴된 건물을 확인할 수 있는데, Fig. 4(B)에서 보듯이 YOLOv3는 파괴된 건물을 탐지하는 데 실패하였다. 이는 파괴된 건물이 일반적인 건물의 형태를 유지하지 못하였고, 건물의 크기 역시 작은 편에 속해 모델이 감지하는 데 어려움을 겪은 사례(hard sample)이다.




Fig. 5. An example of failure cases for classification: (A) Ground truth; (B) Prediction

Fig. 5는 YOLOv3 모델이 건물의 피해 정도에 대한 분류

에 대해 실패한 사례를 보여준다. Fig. 5(A)의 Ground truth를 살펴보면 Major-damage와 Minor-damage 건물이 있는 것을 확인할 수 있는데, Fig. 5(B)에서 보듯이 YOLOv3는 Minor-damage 건물을 Major-damage로 잘못 분류하였다. 이는 Minor-damage나 Major-damage인 건물이 상대적으로 구분이 수월한 No-damage, Destroyed에 비해 형태의 차이가 크지 않기 때문이다. 이 역시 Fig. 4의 작은 건물과 같이 모델이 감지하기 어려운 사례에 속한다.

이러한 실패 사례는 본 연구에서 활용한 세 모델이 1단계 기반 감지기라는 것에 기인한다. 따라서 향후 추가연구가 진행된다면 네트워크 구조의 개선과 모델 최적화를 통해 하드 샘플에 대한 감지 성능을 올려 작은 건물들이 밀집된 국내 도시 지역에 적용할 수 있는 딥러닝 모델을 개발하는 연구가 진행될 수 있을 것으로 기대한다.

4. 요약 및 결론

본 연구에서는 초고해상도 위성영상을 활용한 재난 후 신속한 건물 피해감지 및 평가에 적합한 딥러닝 모델을 선정하고자 하였다. 이를 위해 대표적인 1단계 기반 검출기를 적용하는 딥러닝 모델인 SSD-512, RetinaNet, YOLOv3를 후보 모델로 선정하였다. 또한, 정확한 피해 정도 평가를 위해 건물 피해 평가 데이터셋인 xBD를 학습 자료로 이용하였고, 데이터셋의 불균형 문제를 개선하기 위해 데이터 증강 기법을 활용하여 추가적인 손상된 건물 데이터를 확보하였다. 이후, 각 모델의 피해평가 성능과 이미지 처리속도를 비교하기 위해 정량화된 평가지표인 mAP와 FPS를 도출하였다. 최종적으로 도출된 각 모델의 mAP와 FPS를 동시에 고려하여 신속한 피해감지 및 평가에 가장 적합한 모델을 선정하였다.

재난 현장에서의 건물 피해평가 작업은 높은 감지 성능과 빠른 이미지 처리속도를 동시에 요구하기 때문에, 최적 모델 선정에는 두 조건이 모두 고려되어야 한다. 실험 결과, YOLOv3는 34.39%의 mAP와 46개의 초당 이미지 처리속도를 기록하였다. SSD-512는 31.99%의 mAP와 31개의 이미지 처리속도를 보이며 두 지표에서 전부 YOLOv3에 비해 낮은 성능을 기록하였다. 마지막으로 RetinaNet은 감지 정확도 측면에서 YOLOv3에 비해 1.67% 높은 36.06%의 mAP를 기록하였으나, 이미지 처리속도 측면에서는 YOLOv3의 3분의 1 수준인 14 FPS에 그쳤다. 따라서 다른 재난관리 단계보다 신속성·즉시성이 필요한 재난 대응 작업에서는 높은 이미지 처리속도와 감지 정확도를 보인 YOLOv3의 활용이 적합할 것이다. 다만, 신속한 탐지보다 정밀한 피해조사가 필요한 재난

복구 작업이나 재난피해 지도 작성 등에는 가장 높은 감지 정확도를 기록한 RetinaNet, 또는 2단계 기반 검출기의 활용이 유리할 것이다.

본 연구는 초고해상도 위성영상을 활용한 딥러닝 모델 기반 신속한 건물 피해감지 및 평가를 지원하는 연구이다. 딥러닝 모델의 활용에 있어 목적과 데이터에 따른 최적 모델의 선정은 필수적이고, 최적 모델의 선정에는 정량지표를 바탕으로 한 다양한 모델의 비교-평가가 필요하다. 이에 초고해상도 위성영상에 대한 주요 1단계 기반 검출기 딥러닝 모델의 성능을 비교한 본 연구의 결과는 향후 이루어질 딥러닝 기반 재난 관련 원격탐사 연구나 지자체의 정책 수립과정에 필요한 기초 자료로 활용될 수 있을 것이라 기대한다.

감사의 글

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 글로벌핵심인재양성지원사업의 연구결과로 수행되었음 (S-2022-A0496-00172).

This research was supported by the MSIT(Ministry of Science, ICT), Korea, under the High-Potential Individuals Global Training Program(S-2022-A0496-00172) supervised by the IITP(Institute for Information & Communications Technology Planning & Evaluation)

References

- Alfarrarjeh, A., Trivedi, D., Kim, S. H., and Shahabi, C. (2018). A deep learning approach for road damage detection from smartphone images. In *2018 IEEE International Conference on Big Data (Big Data)*, IEEE, pp. 5201-5204. <https://doi.org/10.1109/bigdata.2018.8621899>
- Baker, S. (1989). San Francisco in ruins: The 1906 serial photographs of George R. Lawrence. *Landscape (Berkeley, Calif.)*, Vol. 30, No. 2, pp. 9-14.
- Bowman, J. and Yang, L. (2021). Few-shot Learning for Post-disaster Structure Damage Assessment. In *Proceedings of the 4th ACM SIGSPATIAL International Workshop on AI for Geographic Knowledge Discovery*, pp. 27-32. <https://doi.org/10.1145/3486635.3491071>
- Carranza-García, M., Torres-Mateo, J., Lara-Benítez, P., and García-Gutiérrez, J. (2020). On the performance of one-stage and two-stage object detectors in autonomous vehicles using camera data. *Remote Sensing*, Vol. 13, No. 1, 89p. <https://doi.org/10.3390/rs13010089>
- Clark, D. G., Ford, J. D., and Tabish, T. (2018). What role can unmanned aerial vehicles play in emergency response in the Arctic: A case study from Canada. *PLoS One*, Vol. 13, No. 12, e0205299. <https://doi.org/10.1371/journal.pone.0205299>
- Deng, L. and Yu, D. (2014). Deep learning: methods and applications. *Foundations and trends in signal processing*, Vol. 7, No. 3-4, pp. 197-387. <https://doi.org/10.1561/9781601988157>
- Ding, J., Zhang, J., Zhan, Z., Tang, X., and Wang, X. (2022). A Precision Efficient Method for Collapsed Building Detection in Post-Earthquake UAV Images Based on the Improved NMS Algorithm and Faster R-CNN. *Remote Sensing*, Vol. 14, No. 3, 663p. <https://doi.org/10.3390/rs14030663>
- Gang, S. M., Kim, D. R., Choung, Y. J., Park, J. S., Kim, J. M., and Jo, M. H. (2016). A plan for a prompt disaster response system using a 3D disaster management system based on high-capacity geographic and disaster information. *Journal of the Korean Association of Geographic Information Studies*, Vol. 19, No. 1, pp. 180-196. (in Korean with English abstract) <https://doi.org/10.11108/kagis.2016.19.1.180>
- Ghaffarian, S., Kerle, N., Pasolli, E., and Jokar Arsanjani, J. (2019). Post-disaster building database updating using automated deep learning: An integration of pre-disaster OpenStreetMap and multi-temporal satellite data. *Remote sensing*, Vol. 11, No. 20, 2427p. <https://doi.org/10.3390/rs11202427>
- Girshick, R., Donahue, J., Darrell, T., and Malik, J. (2015). Region-based convolutional networks for accurate object detection and segmentation. *IEEE transactions on pattern analysis and machine intelligence*, Vol. 38, No. 1, pp. 142-158. <https://doi.org/10.1109/tpami.2015.2437384>
- Groener, A., Chern, G., and Pritt, M. (2019). A comparison of deep learning object detection models for satellite imagery. In *2019 IEEE Applied Imagery Pattern Recognition*

- Workshop (AIPR)*, IEEE, pp. 1-10.
<https://doi.org/10.1109/aipr47015.2019.9174593>
- Gupta, R., Hosfelt, R., Sajeev, S., Patel, N., Goodman, B., Doshi, J., and Gaston, M. (2019). xbd: A dataset for assessing building damage from satellite imagery. *arXiv preprint arXiv:1911.09296*.
<https://doi.org/10.48550/arXiv.1911.09296>
- Jang, E., Kang, Y., Im, J., Lee, D. W., Yoon, J., and Kim, S. K. (2019). Detection and monitoring of forest fires using Himawari-8 geostationary satellite data in South Korea. *Remote Sensing*, Vol. 11, No. 3, 271p.
<https://doi.org/10.3390/rs11030271>
- Jha, M. N., Levy, J., and Gao, Y. (2008). Advances in remote sensing for oil spill disaster management: state-of-the-art sensors technology for oil spill surveillance. *Sensors*, Vol. 8, No. 1, pp. 236-255.
<https://doi.org/10.3390/s8010236>
- Ji, M., Liu, L., and Buchroithner, M. (2018). Identifying collapsed buildings using post-earthquake satellite imagery and convolutional neural networks: A case study of the 2010 Haiti earthquake. *Remote Sensing*, Vol. 10, No. 11, 1689p.
<https://doi.org/10.3390/rs10111689>
- Johnson, R. D. (1994). Change Vector Analysis for disaster assessment: a case study of Hurricane Andrew. *Geocarto International*, Vol. 9, No. 1, pp. 41-45.
<https://doi.org/10.1080/10106049409354440>
- Joyce, K. E., Belliss, S. E., Samsonov, S. V., McNeill, S. J., and Glassey, P. J. (2009). A review of the status of satellite remote sensing and image processing techniques for mapping natural hazards and disasters. *Progress in physical geography*, Vol. 33, No. 2, pp. 183-207.
<https://doi.org/10.1177/0309133309339563>
- Kalantar, B., Ueda, N., Al-Najjar, H. A., and Halin, A. A. (2020). Assessment of convolutional neural network architectures for earthquake-induced building damage detection based on pre-and post-event orthophoto images. *Remote Sensing*, Vol. 12, No. 21, 3529p.
<https://doi.org/10.3390/rs12213529>
- Kim, J., Jeon, H., and Kim, D. J. (2020). Extracting flooded areas in southeast asia using SegNet and U-Net. *Korean Journal of Remote Sensing*, Vol. 36, No. 5_3, pp. 1095-1107. (in Korean with English abstract)
<https://doi.org/10.7780/kjrs.2020.36.5.3.8>
- Kim, Y., Lee, S., Kim, J., and Park, Y. (2017). Disaster management using high resolution optical satellite imagery and case analysis. *Journal of the Korean Society of Hazard Mitigation*, Vol. 17, No. 3, pp. 117-124.
<https://doi.org/10.9798/KOSHAM.2017.17.3.117>
- Lee, J., Im, J., Cha, D. H., Park, H., and Sim, S. (2019). Tropical cyclone intensity estimation using multi-dimensional convolutional neural networks from geostationary satellite data. *Remote Sensing*, Vol. 12, No. 1, 108p.
<https://doi.org/10.3390/rs12010108>
- Li, P., Xu, H., and Song, B. (2011). A novel method for urban road damage detection using very high resolution satellite imagery and road map. *Photogrammetric Engineering & Remote Sensing*, Vol. 77, No. 10, pp. 1057-1066.
<https://doi.org/10.14358/pers.77.10.1057>
- Lin, T. Y., Goyal, P., Girshick, R., He, K., and Dollár, P. (2017). Focal loss for dense object detection. In *Proceedings of the IEEE international conference on computer vision*, pp. 2980-2988.
<https://doi.org/10.1109/iccv.2017.324>
- Liu, W., Angelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., and Berg, A. C. (2016, October). Ssd: Single shot multibox detector. In *European conference on computer vision*, Springer, Cham, pp. 21-37.
https://doi.org/10.1007/978-3-319-46448-0_2
- Ma, L., Li, M., Ma, X., Cheng, L., Du, P., and Liu, Y. (2017). A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 130, pp. 277-293.
<https://doi.org/10.1016/j.isprsjprs.2017.06.001>
- Perez, L. and Wang, J. (2017). The effectiveness of data augmentation in image classification using deep learning. *arXiv preprint arXiv:1712.04621*.
<https://doi.org/10.1109/mlldb54094.2021.00134>
- Pesaresi, M., Gerhardinger, A., and Haag, F. (2007). Rapid damage assessment of built-up structures using VHR satellite data in tsunami-affected areas. *International Journal of Remote Sensing*, Vol. 28, No. 13-14, pp. 3013-3036.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2016).

- You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 779-788.
<https://doi.org/10.1109/cvpr.2016.91>
- Redmon, J. and Farhadi, A. (2018). Yolov3: An incremental improvement. *arXiv preprint arXiv:1804.02767*.
<https://doi.org/10.48550/arXiv.1804.02767>
- Scientific Research Working Group for High Resolution Satellite Remote Sensing/RSSJ. (2011). High Resolution Satellite Remote Sensing Concerning the 2011 off the Pacific Coast of Tohoku Earthquake and Tsunami Disaster. *Journal of The Remote Sensing Society of Japan*, Vol. 31, No. 3, pp. 344-367.
<https://doi.org/10.11440/rssj.31.344>
- Tatham, P. (2009). An investigation into the suitability of the use of unmanned aerial vehicle systems (UAVS) to support the initial needs assessment process in rapid onset humanitarian disasters. *International journal of risk assessment and management*, Vol. 13, No. 1, pp. 60-78.
<https://doi.org/10.1504/ijram.2009.026391>
- Van Etten, A., Hogan, D., Manso, J. M., Shermeyer, J., Weir, N., and Lewis, R. (2021). The multi-temporal urban development spacenet dataset. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 6398-6407.
<https://doi.org/10.1109/cvpr46437.2021.00633>
- Xu, J. Z., Lu, W., Li, Z., Khaitan, P., and Zaytseva, V. (2019). Building damage detection in satellite imagery using convolutional neural networks. *arXiv preprint arXiv:1910.06444*.
<https://doi.org/10.48550/arXiv.1910.06444>
- Xue, B., Huang, B., Wei, W., Chen, G., Li, H., Zhao, N., and Zhang, H. (2021). An Efficient Deep-Sea Debris Detection Method Using Deep Neural Networks. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 14, pp. 12348-12360.
<https://doi.org/10.1109/jstars.2021.3130238>
- Yamazaki, F., Kouchi, K. I., Matsuoka, M., Kohiyama, M., and Muraoka, N. (2004). Damage detection from high-resolution satellite images for the 2003 Boumerdes, Algeria earthquake. In *13th World Conference on Earthquake Engineering, International Association for Earthquake Engineering, Vancouver, British Columbia, Canada*, 13p.
- Yang, B. (2016). GIS based 3-D landscape visualization for promoting citizen's awareness of coastal hazard scenarios in flood prone tourism towns. *Applied Geography*, Vol. 76, pp. 85-97.
<https://doi.org/10.1016/j.apgeog.2016.09.006>
- Yang, B. and Jahan, I. (2018). Comprehensive assessment for post-disaster recovery process in a tourist town. *Sustainability*, Vol. 10, No. 6, 1842p.
<https://doi.org/10.3390/su10061842>
- Yang, Y., Xie, G., and Qu, Y. (2021). Real-time Detection of Aircraft Objects in Remote Sensing Images Based on Improved YOLOv4. In *2021 IEEE 5th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, IEEE, Vol. 5, pp. 1156-1164.
<https://doi.org/10.1109/iaeac50856.2021.9390673>
- Zou, Z., Shi, Z., Guo, Y., and Ye, J. (2019). Object detection in 20 years: A survey. *arXiv preprint arXiv:1905.05055*.
<https://doi.org/10.48550/arXiv.1905.05055>