

국내학회지 논문 리뷰를 통한 원격탐사 분야 딥러닝 연구 동향 분석 Analysis of Deep Learning Research Trends Applied to Remote Sensing through Paper Review of Korean Domestic Journals

이창희¹⁾ · 윤예린²⁾ · 배세정³⁾ · 어양담⁴⁾ · 김창재⁵⁾ · 신상호⁶⁾ · 박소영⁷⁾ · 한유경⁸⁾

Lee, Changhui · Yun, Yerin · Bae, Saejung · Eo, Yang Dam · Kim, Changjae
Shin, Sangho · Park, Soyoung · Han, Youkyung

Abstract

In the field of remote sensing in Korea, starting in 2017, deep learning has begun to show efficient research results compared to existing research methods. Currently, research is being conducted to apply deep learning in almost all fields of remote sensing, from image preprocessing to applications. To analyze the research trend of deep learning applied to the remote sensing field, Korean domestic journal papers, published until October 2021, related to deep learning applied to the remote sensing field were collected. Based on the collected 60 papers, research trend analysis was performed while focusing on deep learning network purpose, remote sensing application field, and remote sensing image acquisition platform. In addition, open source data that can be effectively used to build training data for performing deep learning were summarized in the paper. Through this study, we presented the problems that need to be solved in order for deep learning to be established in the remote sensing field. Moreover, we intended to provide help in finding research directions for researchers to apply deep learning technology into the remote sensing field in the future.

Keywords : Remote Sensing, Deep Learning, Analysis of Research Trend, Image Acquisition Platform, Open Source Data

초 록

우리나라 원격탐사 분야에서는 2017년을 기점으로 딥러닝의 뛰어난 성능을 바탕으로 연구 성과를 나타내기 시작하여, 현재는 영상 전처리부터 활용까지 원격탐사의 거의 모든 분야에서 딥러닝을 적용하는 연구가 수행되고 있다. 원격탐사 분야에 적용된 딥러닝의 연구 동향 분석을 수행하기 위해, 2021년 10월까지 출판된 원격탐사 분야에 딥러닝이 적용된 국내 논문들을 수집하였다. 수집된 60여 편의 논문들을 바탕으로 딥러닝 네트워크 목적, 원격탐사 활용 분야, 원격탐사 영상 취득 탑재체별로 나누어 연구 동향 분석을 수행하였다. 또한, 논문에서 훈련자료 구축에 효과적으로 이용되었던 오픈소스데이터들을 정리하였다. 본 논문을 통해 현시점에서 딥러닝이 원격탐사 분야에 자리 잡기 위해 해결해야 할 문제점들을 제시하면서, 향후 연구자들의 원격탐사 분야에 딥러닝 기술을 접목하기 위한 연구 방향을 설정하는 데 도움을 제공하고자 한다.

핵심어 : 원격탐사, 딥러닝, 연구동향분석, 영상 취득 탑재체, 오픈소스데이터

Received 2021. 11. 23, Revised 2021. 12. 06, Accepted 2021. 12. 10

- 1) Dept. of Civil Engineering, Master student, Seoul National University of Science and Technology (E-mail: ckdgmj914@seoultech.ac.kr)
- 2) Dept. of Civil Engineering, Master student, Seoul National University of Science and Technology(E-mail: laurayun7@seoultech.ac.kr)
- 3) School of Civil Engineering, Undergraduate student, Seoul National University of Science and Technology (E-mail: sjbae1102@naver.com)
- 4) Member, Professor, Dept. of Civil and Environmental Engineering, Konkuk University (E-mail: eoandrew@konkuk.ac.kr)
- 5) Member, Associate Professor, Dept. of Civil and Environmental Engineering, Myongji University (E-mail: cjkim@mju.ac.kr)
- 6) Deputy Director, Geographic Information Division, National Geographic Information Institute, Ministry of Land, Infrastructure and Transport (E-mail: ssh1263@korea.kr)
- 7) Senior Officer, Geographic Information Division, National Geographic Information Institute, Ministry of Land, Infrastructure and Transport (E-mail: soyoung331@korea.kr)
- 8) Member, Corresponding Author, Assistant Professor, Dept. of Civil Engineering, Seoul National University of Science and Technology (E-mail: han602@seoultech.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. 서 론

딥러닝의 근간이 되는 인공지능(AI: Artificial Intelligence)은 1940년대에 McCulloch and Pitts (1943)에 의해 처음 소개된 개념으로, 컴퓨터상에서 생성된 인공 신경을 그물망 형태로 연결함으로써 컴퓨터를 통해 사람 뇌에서 동작하는 아주 간단한 기능을 흉내 낼 수 있음을 증명하였다. 이렇듯 인공지능은 컴퓨터가 인간 지능을 모방할 수 있도록 하는 기술을 말하며, 여기에는 기계학습(machine learning)이 포함된다. 기계학습이란 컴퓨터가 스스로 학습하여 예측모형을 개발하는 인공지능의 한 분야로, 1970년대 인공지능의 제2의 전성기와 함께 발전하였다. 하지만 이 시기에는 한정된 분야에만 기계학습의 적용이 가능하였고, 수동적인 지식의 입력 및 모순되는 지식의 충돌 등의 여러 문제로 제한적인 성공을 거두는 것에 그쳤다. 이후 LeCun *et al.* (1998)에 의해 CNN (Convolution Neural Network) 모델의 시초인 LeNet이 개발되고, 초기값 설정에 따라 학습의 결과가 상이한 사실을 토대로, 가중치 초기화기법을 적용하여 딥러닝의 학습 안정성을 향상시킨 제한 볼츠만 기계(RBM: Restricted Boltzmann Machines) 모델이 개발되었다(Hinton, 2009). 본 연구들을 기반으로 신경망 모델이 주목받기 시작하면서, 신경망 모델의 이름을 딥러닝으로 변경하여 오늘날까지 이어지고 있다.

딥러닝이란 4차 산업혁명의 핵심기술 중 하나인 인공지능을 구현하는 방법론으로 4세대 인공지능으로 불린다(Song and Kim, 2017). 과거에는 하드웨어의 기술적 한계로 인한 침체기를 맞았지만, 최근에는 딥러닝의 필수 3요소라고 판단되는 하드웨어, 데이터셋과 벤치마크(benchmark), 알고리즘(algorithm)이 발전함에 따라 딥러닝의 진보를 이끌었다. 2012년경부터 딥러닝이 컴퓨터 비전 분야에서 최고의 성능을 내면서 국내외 연구자들과 대형 IT 기업 및 연구소의 이목을 집중시켰으며, 현재에는 컴퓨터 비전 분야에 국한되지 않고 다양한 분야로 적용의 폭을 넓혀가고 있다. 학술연구정보서비스(RISS: Research Information Sharing Service)에서 2019년 12월까지 등록된 논문을 대상으로 ‘인공지능’, ‘기계학습’, ‘딥러닝’의 키워드를 이용해 검색한 결과, 인공지능은 5,521편, 기계학습은 2,939편, 딥러닝은 2,112편의 논문이 출판된 것을 확인하였고, 2015년부터 2016년까지는 인공지능 논문 600%, 기계학습 논문 176%, 딥러닝은 316%의 증가세를 보였다(Park, 2020). 이런 증가세를 보일 수 있었던 근본적인 이유로는 딥러닝에 사용하는 도구의 대중화 영향이 크다. 초창기 딥러닝은 C++과 CUDA를 다룰 수 있는 전문가만이 이용 가능하다는 한계점이 있었다. 이후 Theano와 TensorFlow

와 같은 심볼릭 텐서 조작 프레임워크의 개발 및 Keras와 같은 사용자 편의 도구의 개발이 딥러닝 연구의 활성화 계기가 되었다.

2012년에 딥러닝 모델인 AlexNet이 발표되어 컴퓨터 비전 객체 인식대회인 ILSVRC (ImageNet Large Scale Visual Recognition Challenge)에서 우승을 하면서, 영상처리 분야에서 딥러닝 기법이 기존의 기계학습 기법에 비해 두각을 나타내기 시작하였다. 현재에는 영상처리 분야 뿐만 아니라 다양한 분야에서 인공지능의 활용에 대한 지속적인 연구가 수행 중에 있으며, 4차 산업혁명의 핵심기술로 빅데이터, 인공지능이 포함되며 현재까지도 많은 연구자들의 관심 속에서 발전을 거듭해 나가는 추세이다.

이렇듯 2010년 이후 국외에서는 여러 분야에서 인공지능을 활용한 연구가 수행됨에 따라 원격탐사 분야에서도 딥러닝을 접목하는 기술이 다양하게 제안되고 있다. 이와 더불어 국내에서도 4차 산업혁명이 본격화되기 시작한 2017년을 기점으로 딥러닝 기술을 접목한 연구가 증가하는 추세를 보이고 있다. 특히 원격탐사의 다양한 연구 주제에 대해 딥러닝을 적용하는 연구가 활발히 수행됨에 따라, 출판되는 딥러닝 관련 논문의 수가 급증하고 있다. 이에 따라 국내 원격탐사 분야에서 딥러닝 기술의 논문 연구 동향 분석이 필요한 시점이라고 판단된다.

본 논문에서는 대한원격탐사학회지, 한국측량학회지 등 현재까지 출판된 원격탐사 분야의 딥러닝 기반 국내 학회지 논문에 대한 분석을 수행하였다. 학술검색을 통해 확인된 60여 편의 논문을 분석하여 가장 많이 사용된 딥러닝 네트워크를 전체 영상에 대해 미리 정의된 클래스로 분류를 수행하는 장면분류(scene classification), 영상 내에 존재하는 물체를 탐지하고 해당 물체의 위치 정보를 파악하는 객체탐지(object detection), 영상에 존재하는 전체 화소에 대해 미리 정의된 클래스로 분류를 수행하는 의미론적분할(semantic segmentation), 학습 과정에서 모델 스스로 데이터상의 정보를 찾아내서 새로운 데이터를 생성하는 영상생성(image generation) 등의 목적별로 분류하여 특성을 파악하였다. 또한, 딥러닝 기술을 적용한 원격탐사 분야 연구 동향 분석을 통해, 원격탐사 활용 분야별 및 탑재체별로 어떠한 특성의 차이를 보이는지 도출하였다. 마지막으로 딥러닝 적용에 필요한 훈련자료 구축에 효율적으로 사용된 오픈소스 데이터들을 정리하였다. 이를 통해 현시점에서 딥러닝이 원격탐사 분야에 자리 잡기 위해 해결해야 할 문제점을 제시하면서, 향후 연구자들의 원격탐사 분야에 딥러닝 기술을 접목하기 위한 연구 방향을 설정하는 데 도움을 제공하고자 한다.

2. 국내 원격탐사 분야 딥러닝 기술 적용사례 조사

2장에서는 국내 원격탐사 분야 딥러닝 기술 적용 연구 동향을 분석하였다. 관련 논문 수집을 위하여 국내 원격탐사 분야 논문이 주로 출판되는 대한원격탐사학회지, 한국측량학회지, 대한공간정보학회지 등을 포함하여 최근에는 원격탐사 기법으로 취득된 데이터들이 다양한 분야에서 이용되고 있으므로, 학술검색 서비스를 이용하여 분야를 특정하지 않고 원격탐사 기반 딥러닝 관련 연구논문을 수집하였다. 수집된 논문은 총 60편, 출판된 국내학회지는 13종류로 다양한 분야에 딥러닝 기술이 접목되고 있는 것을 알 수 있다.

첫 번째로, 위의 수집된 논문을 토대로 발표연도별로 딥러닝 논문 현황을 분석하였다. 2017년 대한원격탐사학회에서 발표된 “딥러닝 기반의 초분광 영상분류를 사용한 환경공간정보 시스템 활용” 논문(Song and Kim, 2017)을 시작으로, 2018년 6편, 2019년 13편, 2020년 26편, 2021년에는 14편의 논문이 출판된 것을 확인하였다. Fig. 1을 통해 출판되는 원격탐사 분야의 딥러닝 논문의 수는 매해 높은 비율로 늘어나는 것을 알 수 있었다. 2020년에 비해 2021년 논문의 수가 줄어든 이유는, 본 연구에서 조사한 논문들은 2021년 10월까지 출판된 논문들을 대상으로 분석하였기 때문이다. 이 시점에서도 원격탐사 분야에 딥러닝을 적용한 연구가 활발히 수행되고 있으며, 2017년부터 2021년까지 붉은색 실선으로 표현된 선형 추세선을 통해 2021년과 그 이후에도 많은 수의 논문이 추가로 발표될 것으로 판단된다. 이런 현상의 주된 이유로는, 딥러닝이 영상처리 분야에서 고전적인 방식의 기계학습에 비해 높은 정확도와 효율성을 가지고 있고(Ma et al., 2019), 이는 원격탐사기법으로 취득된 영상에 대해서도 동일한 결과를 나타내기 때문이다. 이와 더불어 연구자들에 의해 지속적으로 네트워크가 수정, 개발되어 연구의 정확도가 향상되고 있기 때문에 판단된다.




Fig. 1. Number of deep learning papers in the remote sensing field by presentation year (investigated until October 2021)

두 번째로는, 조사된 논문들을 학술지별로 발표된 논문의 수에 따라 분류하여 분석하였다. Fig. 2는 조사를 통해 수집한 논문들이 출판된 학회와 학회별 딥러닝 관련 출판 논문 수를 나타내고 있다. 대한원격탐사학회지에서 가장 많은 26편의 딥러닝 관련 논문이 출판되었으며, 한국측량학회지에서 13편, 대한토목학회지 5편, 대한공간정보학회지 4편, 한국지리정보학회지 3편, 기타 학회지에서 9편의 딥러닝 논문이 발표되었다. 개발된 대다수의 딥러닝 네트워크는 영상작용에 최적화된 알고리즘이기 때문에, 위성 및 드론 등의 원격탐사 탐재체로부터 취득된 영상을 활용하는 연구논문들의 발표가 활발한 대한원격탐사학회지와 한국측량학회지에서 많은 논문이 발표된 것을 알 수 있다. 기타 항목에 포함된 한국인터넷 정보학회지, 한국안전학회지, 한국전자통신학회지, 한국전자거래학회지 등 원격탐사와 직접적인 관계가 없는 분야에서도 원격탐사 기법으로 취득된 데이터를 이용한 딥러닝 연구를 학회별로 최소 1편에서 최대 2편가량 발표된 것을 확인하였다.




Fig. 2. Number of deep learning papers in the remote sensing field distributed by Korean domestic journal (investigated until October 2021)

세 번째로, 수집된 저널을 대상으로 연구에 이용된 딥러닝 모델의 목적에 따라 분류를 수행한 결과, 장면분류, 영상 내 객체탐지, 영상의 의미론적분할, 영상생성의 4종류로 나눌 수 있었다. 이에 포함되지 않는 연구의 경우 기타 항목에 포함하였다. Fig. 3에서 확인 할 수 있듯이, 영상 내에 있는 객체들을 의미 있는 단위로 분할하는 의미론적 분할 연구가 25편으로 가장 많았다. 다음으로는 영상 내 객체탐지 연구가 15편으로 뒤를 이었으며, 장면분류 11편, 영상생성 5편, 기타항목 4편으로 분류가 된 것을 확인하였다. 원격탐사 분야에서는 광범위한 지역의 영상을 분석하여 지표면에 대한 정보를 분석하는 연구가 수행되고 있다. 의미론적 분할은 영상의 각 화소마다 미리 정의한 클래스를 부여하는 방식으로 분류를 수행한다. 이를 원격탐사에 적용할 경우 영상 내 존재하는 모든 화소에 대한 정보취득

이 가능하고, 광범위한 영역의 데이터를 분석하는 원격탐사 분야 연구에 적합하다. 이러한 장점이 의미론적 분할 연구가 전체 연구의 40% 이상의 비율을 차지하는 이유로 사료된다. 객체탐지 분야도 딥러닝이 적용되기 이전부터 많은 연구가 수행되었던 항목으로, 영상 내에서 객체를 인식하고 해당 객체의 위치 정보를 파악하느 것을 목적으로 한다. 이는 원격탐사 데이터와 같이 넓은 영역에서 특정 객체의 인식에 효율적이며, 안보, 도시계획수립, 재난 혹은 재해의 피해복구 등 다양한 방면에 이용될 수 있다. 장면분류는 영상 한 장을 정해진 클래스로 분류를 수행한다. 하지만 원격탐사 분야의 경우 영상이 넓은 범위를 포함하고 있으므로, 원영상을 작은 패치 단위로 나누어서 해당 패치별로 분류를 수행하는 방식으로 연구가 수행되고 있다. 이러한 연구 수행방법으로 인해 원격탐사 데이터에 장면분류를 적용한 연구의 결과는 의미론적분할과 비슷한 형태의 결과를 도출할 수 있다. 영상생성은 학습데이터로 모델을 학습시켜, 사용자의 개입 없이 모델 스스로 데이터 속의 정보를 바탕으로 새로운 데이터를 만들어 낸다. 모델 스스로 데이터를 만들어 내는 특성이 있으므로, 각종 센서의 융합활용을 통해 다양한 데이터의 제작이 가능하다. 기타 항목에는 적지분석(Heo et al., 2020), 지표면 온도산출(Kim et al., 2020), 수정된 VAE(Baek and Yom, 2019)를 이용한 영상생성 연구 등이 있다.




Fig. 3. Number of deep learning papers in the remote sensing field distributed by purpose of deep learning network (investigated until October 2021)

네 번째로, 딥러닝 모델에 상관없이, 원격탐사 활용 분야에 따른 딥러닝 연구 동향 분석을 수행하였다. Fig. 4를 통해 확인 할 수 있듯이, 영상분류, 객체탐지, 영상융합, 변화탐지의 순서로 많은 연구가 수행된 것을 확인할 수 있다. 영상분류 분야에서는 토지피복분류 연구가 많이 수행된 것을 확인하였다. 원격탐사의 장점 중 하나가 넓은 지역의 정보를 신속하게 추출 가능한 것으로, 광범위한 지역의 토지피복분류에 적합하

다(Park et al., 2001). 이러한 이유로 원격탐사분야에서는 토지피복분류 정확도를 향상하기 위한 연구가 많이 수행되고 있는데, 딥러닝 기술이 적용된 후에도 활발히 진행되고 있다. 본 논문에서 조사한 60편의 논문 중에서 토지피복분류 연구가 11편을 차지하고 있었다. 토지피복분류 외에 수행된 영상분류 연구로는 식생층위구조 추정(Cha et al., 2020), 작물분류(Kim et al., 2018; Kwak et al., 2019; Park et al., 2019), 수계영역 분류(Jeon et al., 2020), 부유조류 분류(Kim et al., 2020) 등이 있었다. 객체탐지 분야는 학습데이터에 정의된 클래스의 객체들과 위치 정보를 찾는 것이 목적이다. 객체탐지는 위성영상이나 무인항공기에서 영상 내에 존재하는 다양한 객체(자동차, 배, 건물 등)를 탐지하는 연구가 대표적이다(Chung et al., 2020). 영상융합은 대부분 GAN (Generative Adversarial Network) 모델을 이용한 초해상화 연구가 대표적이며(Choi et al., 2020; Choi et al., 2020), SAR 영상의 색상구현(Ku and Chung, 2018), 다중플랫폼을 활용한 엄밀정사영상 생성 연구(Shin et al., 2020) 등이 수행되었다. 변화탐지는 서로 다른 시기에 취득된 영상을 이용하여 동일한 지역에서 발생한 공간 및 분광 변화의 유무를 분석하는 것이 목적이다. 본 논문에서 조사한 저널 중에서는 고해상도 위성영상을 이용한 변화탐지 연구가 대표적이다(Song et al., 2020; Seong et al., 2021). 오픈데이터셋을 활용한 변화탐지 연구도 있었다(Song et al., 2019). 위에서 언급한 네가지 분야에 포함되지 않는 연구들은 기타에 포함하였다. 이에 포함된 연구로는 연안해역의 고해상도 해상풍 산출 연구(Joh et al., 2021)와 교량의 손상 위치 추정방법을 제안하는 연구(Lee et al., 2020), 적지 분석연구(Heo et al., 2020) 등이 있었다. 마지막으로 객체탐지와 변화탐지를 함께 수행한 연구(Wi et al., 2020)와 영상분류와 영상융합을 함께 수행한 연구(Seong et al., 2021)가 있었다. 해당 연구들은 각각 속한 연구에서 중복으로 카운트하여 Fig. 4에 표현하였다.




Fig. 4. Number of deep learning papers in the remote sensing field distributed by research topic (investigated until October 2021)

마지막으로 연구에 이용된 데이터의 취득방식, 즉 센서의 탑재체에 따른 분석을 수행하였다(Fig. 5). 위성영상을 활용한 딥러닝 연구논문은 전체 60편 중 24편으로 전체 비율 중에서 약 40%를 차지하고 있을 정도로 위성영상에 딥러닝을 적용한 연구가 많이 수행되었음을 알 수 있다. 다음으로는 드론으로 취득된 영상을 이용한 연구 10편과 항공기(aircraft)로 취득된 영상을 이용한 연구 10편, 기타 자료를 이용한 연구 15편이 수행되었음을 확인하였다. 60편의 논문 중에서 다중센서를 이용하여 수행된 연구도 확인하였다. 총 5편의 다중센서를 이용한 연구 중 2편은 탑재체는 위성으로 동일하나, 서로 다른 종류의 위성으로 취득된 영상을 이용하여 딥러닝 모델의 학습 및 평가를 수행하였고, 1편은 드론에 탑재된 다중센서를 통해 취득된 영상을 이용하였다. 이 외 다른 2편의 연구는 영상이 취득된 센서의 탑재체가 상이한 경우로, 드론영상과 위성영상을 함께 활용하여 작물분류에서 기계학습 및 딥러닝 알고리즘의 분류 성능을 평가한 연구(Kim et al., 2018)와 위성영상과 항공영상을 함께 이용하여 토지피복관련 인공지능 학습데이터 구축 및 의미론적 분할 모델의 성능 비교 연구(Lee and Lee, 2021)가 있었다. Lee and Lee(2021)는 항공영상과 위성영상을 함께 이용하여 다중 해상도 데이터셋을 구축하고 이를 검증하였다. 동일한 객체에 대하여 cm급 해상도의 항공영상과 m급 해상도의 위성영상을 함께 학습데이터로 이용하여 토지피복분류 수행결과 성공적인 결과값을 취득하였음을 확인하였다. 앞서 언급한 다중센서를 이용한 연구들과 같이 다중 해상도 데이터셋을 활용할 경우 단일 해상도로 구축된 데이터셋 보다 다양한 연구를 수행할 수 있을 것으로 사료된다. 향후에도 다중 해상도 데이터셋을 이용한 연구는 원격탐사분야에서 딥러닝이 다방면으로 적용되는데 있어 중요하게 작용할 것으로 판단된다.




Fig. 5. Number of deep learning papers in the remote sensing field distributed by image acquisition platform (investigated until October 2021)

3. 딥러닝 네트워크 목적에 따른 원격탐사 연구 동향 분석

3장에서는 수집한 국내 논문들을 딥러닝 네트워크 목적에 따라 분류하여 분석하였다. 분석결과, 장면분류와 객체탐지, 의미론적분할, 영상생성 총 4분야의 연구가 주로 수행되고 있음을 확인하였다. 이에 따라 각 목적을 대표할 수 있는 네트워크나 수집된 논문 중 가장 많이 이용된 네트워크를 선정하여 구조를 분석하고 특징에 대하여 자세하게 서술하였다. 이와 더불어 각 목적별로 이용되고 있는 네트워크의 종류들과 발전 현황에 대해 서술하였다.

3.1 장면분류

본 논문에서 조사한 60여 편의 논문 중 장면분류 분야 논문은 11편을 차지하고 있다. 장면분류 연구에서 많이 이용된 AlexNet의 특징들에 대해 서술하였다. Fig. 6은 AlexNet의 네트워크 구조를 나타내는 그림이다.




Fig. 6. Architecture of AlexNet(Krizhevsky et al., 2012)

딥러닝의 근간인 LeNet을 발전시켜 개발된 AlexNet은 2012년 ILSVRC 대회의 우승을 통해 성능을 입증하고, 딥러닝을 유행시킨 모델이다(Jang and Chung, 2019). AlexNet은 총 5개의 컨볼루션 계층(convolution layer)과 3개의 전결합 계층(fully connected layer)으로 구성되어 있다. AlexNet은 구조적인 면에서 LeNet과 큰 차이가 없고, AlexNet이 2개의 GPU로 병렬연산을 수행하기 위해서 병렬적인 구조로 설계된 것이 AlexNet과 LeNet의 가장 큰 차이점이다. Krizhevsky et al. (2012)에 의하면 병렬 구조 설계를 통해 비교적 빠른 학습 속도와 16.4%의 에러율로 기존에 비해 크게 향상되었다고 서술하였다. 활성화 함수는 ReLu를 사용해 속도를 개선하였는데, LeNet에서 이용된 Tanh 비해 6배 빠른 학습 속도를 나타내었다(Krizhevsky et al., 2012). LeNet은 average pooling 기법을 이용한 반면 AlexNet은 Max pooling 기법을 이용한다. 이와 더불어 모델의 과적합(overfitting)을 방지하기 위해 네트워크 학습 과정에서 다양한 기법을 적용하였다. AlexNet에 추가된 대표적인 기법으로는 적은 양의 데이터에 2차원 변환

요소를 적용하여 딥러닝 모델이 다른 데이터로 인식하게 함으로써 데이터의 양을 늘리는 데이터 증강(data augmentation) 기법을 적용하였다. 또한 네트워크에서 학습의 수행 중에 랜덤한 뉴런의 가중치를 0으로 만들어 뉴런 삭제를 통해 연산량을 줄임으로써 네트워크 실행 속도의 향상을 가져오는 dropout 기술을 이용하였다.

AlexNet을 시작으로 ILSVRC에서 GoogLeNet, VGG, ResNet 등의 다양한 모델들이 발표되었다. 모델에 관한 연구가 지속적으로 수행되면서, 기존보다 정확도가 높고 속도가 빠른 모델들이 등장하였다. 2015년 ILSVRC에서 ResNet의 발표 이전에는 모델의 층이 깊어지면 모델의 성능이 저하되는 한계점에 부딪혀, 얇은 층의 모델을 이용하였다. 이는 gradient vanishing 문제로 인해 모델의 학습이 잘 이루어지지 않기 때문에, ResNet에서는 skip connection을 도입하여 이 문제를 해결하였다. 이를 통해 3.57%의 에러율을 얻을 수 있었고, 이는 사람의 에러율인 5%보다 뛰어난 모델로 평가받고 있다. 그뿐만 아니라 층이 깊어짐에 따라 연산량이 증가하는 문제를 해결하기 위해 bottleneck 구조를 적용하여 신경망을 단순화하였다(He et al., 2016).

3.2 객체탐지

본 논문에서 조사한 60여 편의 저널 중 객체탐지 분야 논문은 15편을 차지하고 있다. 객체탐지의 경우 영상 내에 존재하는 물체를 탐지하고, 해당 물체의 위치 정보를 파악하는 것을 최종 목표로 한다. 객체탐지 분야에서 딥러닝 알고리즘은 영역 제안(region proposal)을 통해 객체를 탐지하는 방법인 이단계 탐지(two-stage detector) 방식과 정해진 위치와 정해진 크기의 객체만 찾는 단일 단계 탐지(single-stage detector) 방식으로 나뉜다(Park et al., 2019).

첫 번째 방법인 이 단계 탐지방법은 분류(classification)와 영역제안을 순차적으로 수행하여 객체탐지 결과를 얻는다. 영역제안 과정에서는 객체를 포함할 가능성이 높은 영역을 선택적 탐색(selective search) 같은 컴퓨터 비전 분야의 기술이나, 딥러닝 기반의 영역 제안 네트워크인 RPN (Region Proposal Network)를 통해 선택한다. 이 단계 탐지방법을 이용하는 딥러닝 네트워크의 종류로는 Faster R-CNN, R-FCN (Fully Connected Network) 등이 포함되어 있다. 이는 높은 정확도를 제공할 수 있는 장점이 있지만, 객체탐지에 앞서 두 단계를 거쳐야 하므로 단일 단계 탐지방법에 비해 계산 과정이 복잡하고 계산의 빈도가 많아 처리속도가 느리다는 단점이 존재한다(Bak et al., 2020).

두 번째 방법인 단일 단계 탐지방법은 분류와 영역 제안

을 동시에 수행하여 객체탐지 결과를 얻는다(Lim and Do, 2021). 이 알고리즘을 이용하는 네트워크들은 YOLO 시리즈, SSD (Single Shot multi Detection) 등이 있다. 해당 네트워크들은 원본 이미지를 고정된 사이즈의 그리드 영역으로 분할한다. 이후 알고리즘이 각 영역에 대해 형태와 크기가 미리 결정된 객체의 고정 개수를 예측하는 방식으로 수행된다. 이 단계 탐지방법에 비해 정확도는 떨어지지만, 처리속도가 매우 빠르고 모델의 구성이 간단한 장점이 있다(Ha et al., 2021).

딥러닝 네트워크가 발전을 거듭하면서 Retina-Net (Lin et al., 2017), M2Det (Zhao et al., 2019) 등과 같은 최신 네트워크들은 단일 단계 탐지방법에 속하지만, 이 단계 탐지방법과 비슷하거나 혹은 더 높은 정확도를 취득할 수 있게 되었다. 아래에서는 저널 조사 결과 객체탐지 연구에서 많이 이용된 대표적인 이 단계 및 단일 단계 탐지방법인 Faster R-CNN과 YOLO 네트워크에 대해 서술하였다.

3.2.1 이 단계 탐지방법 – Faster R-CNN

Faster R-CNN 네트워크는 Fast R-CNN에서 발전한 네트워크로, 기존 Fast R-CNN 네트워크의 구조는 그대로 계승하면서, 선택적 탐색 부분을 제거하고 딥러닝 기술을 적용한 RPN를 통해 ROI (Region of Interest)를 계산한다(Shin and Hong, 2018). Kim et al. (2019)에 의하면 이를 통해 기존의 R-CNN, Fast R-CNN에 비해 속도가 획기적으로 개선된 것을 확인할 수 있다고 서술하였다. Fig. 7은 Faster R-CNN에서 ROI를 찾는 과정에 대한 그림이다.




Fig. 7. Architecture of Faster R-CNN network

Faster R-CNN의 전 모델인 Fast R-CNN에서 ROI pooling을 이용하여 속도를 높였지만, 여전히 영역 제안에서 많은 시간이 소요되는 문제점이 있었다. 이는 기존의 선택적 탐색 방법이 CPU를 이용하여 수행되기 때문에 발생하는 한계로, 이 과정을 딥러닝에 적용하여 GPU를 사용한다면 속도향상이 가능하다. 그것을 목적으로 Faster R-CNN에서 RPN을 도입하였고, RPN은 이전 과정인 CNN 모델에서 취득한 특징지도

(feature map)를 입력값으로 이용한다. 이 과정에서 앵커박스(anchor box) 개념을 이용하는데, 이는 미리 정의된 형태를 가진 경계박스를 말한다. 앵커박스가 Sliding window 방식으로 특징지도를 탐색하며 객체의 유무와 위치를 추측하게 된다. 특징지도의 모든 좌표에 대해 이 과정을 수행하게 된다. 특징지도가 $14 \times 14 \times 512$ 차원, 앵커박스의 개수를 9개로 가정한다면, 추출된 ROI의 수는 $14 \times 14 \times 9$, 즉 1764개가 된다. 앵커박스의 장점으로는 특징지도의 위치나 값에 따라 변하지 않기 때문에 계산하기가 편리하다. 이런 장점으로 인해 물체의 위치가 변해도, 앵커박스의 크기는 변하지 않기 때문에 ROI가 달라질 확률이 매우 작다.

3.2.2 단일 단계 탐지방법 - YOLO (You Only Look Once)

기존 R-CNN 계열의 알고리즘이 딥러닝 기반의 객체탐지 방법론의 발전을 이끌었으나, 실시간 처리 속도를 필요로 하는 분야에 적용하기에는 부족한 부분이 있었다. 이러한 문제를 해결하기 위해 실시간에 가까운 처리를 위한 보다 빠른 딥러닝 기반의 알고리즘인 YOLO가 개발되었다(Park *et al.*, 2020).

YOLO 모델은 CVPR (Computer Vision and Pattern Recognition) 2016에서 처음으로 발표된 네트워크로, 하나의 컨볼루션 네트워크를 통해 대상의 위치와 클래스를 한 번에 예측하는 최초의 단일 단계 탐지방법의 객체탐지 알고리즘이다. 1초에 45 프레임의 처리속도를 나타내면서, 당시 가장 빠른 속도의 객체탐지 네트워크로 평가받았다. 하지만 YOLO 초기모델은 작은 물체들이 모여있는 영상의 경우 검출이 힘들다는 단점이 있는데, 이는 공간적 제약(spatial constraints)으로 인한 문제로 그리드(grid)마다 단 하나의 물체만을 검출하도록 설계되어 있기 때문이다. 이러한 한계점을 해결하기 위해 YOLO 네트워크는 지속적으로 개발을 통해 발전하였으며, 2021년 현재 까지 YOLO는 v1부터 v4까지 다양한 버전이 개발되어 있다. 본 논문에서는 YOLO 네트워크의 시초인 v1에 대해 분석하고, v1에서 v4에 이르기까지 발전된 내용을 간단히 서술하고자 한다. Fig. 8은 YOLO 네트워크의 구조를 나타낸다.




Fig. 8. Architecture of YOLO v1 network(Redmon *et al.*, 2016)

YOLO의 CNN 구조는 장면분류 분야에서 사용되는 GoogLeNet 모델과 유사하다. YOLO는 24개의 컨볼루션 계층(convolution layer)과 2개의 전결합계층(fully connected layer)으로 구성되어 있다. 이 구조에서 컨볼루션 계층은 입력 영상으로부터 특징을 추출하고, 전결합계층은 클래스 확률과 바운딩 박스(bounding box)의 좌표를 예측한다. 본 모델의 가장 큰 장점으로는, 학습의 파이프라인이 기존의 객체탐지 모델들에 비해 간단하므로 학습과 예측의 속도가 빠르다는 점과 모든 학습 과정이 영상 전체를 통해 일어나므로, 단일 대상의 특징뿐 아니라 영상 전체의 맥락을 학습하게 된다는 점이다. Fast R-CNN과 같은 모델은 주변 정보까지는 처리를 못 하므로, 아무 물체가 없는 배경(background)에 반점과 같은 잡음(noise)이 있으면 그것을 물체로 인식하는 반면, YOLO는 앞서 언급한 모델의 특성상 배경 오류를 최소화할 수 있다. 단점으로는 위에서 언급한 공간적 제약과 바운딩 박스 형태가 데이터를 통해 학습되므로 새로운 형태의 바운딩 박스의 경우 예측 정확도가 떨어지는 단점이 있다. 이는 후속 버전에서 다양한 데이터 증강 방법을 적용하여 개선되었다. 초기의 YOLO v1은 백본 네트워크(backbone network)로 VGG-16을 이용했지만, v2 이후로는 Darknet-19를 이용하여 전결합계층을 제거하여 가중치 파라미터 수를 낮추는 효과를 얻었고, 이를 통해 더욱 빠른 속도로 객체 검출이 가능하게 되었다. 가장 최근 발표된 v4는 학습방법을 추가 및 보완하고, CSPDarknet-53을 백본 네트워크로 이용하여 레이어의 수와 파라미터수를 늘렸음에도 불구하고 다른 네트워크보다 빠른 속도와 높은 정확도를 보인다.

3.3 의미론적 분할

영상의 의미론적 분할은 조사한 60여 편의 저널 중 25편으로 가장 많은 논문이 발표된 연구 분야이다. 의미론적 분할은 미리 정의된 몇 개의 클래스에 대해 영상에 대한 분류를 수행한다는 점에서 앞서 언급하였던 장면분류와 유사하지만, 장면분류는 영상 전체를 정해진 클래스로 분류를 수행하는 것이고, 의미론적 분할은 영상의 개개 화소별로 분류가 진행된다는 점에서 차이가 있다. 의미론적 분할의 경우 인접한 개체는 동일 클래스로 판단하는 반면, 동일 클래스라도 개체가 다른 경우 이들에 대한 분할이 가능한 개체분할(instance segmentation) 방법도 존재한다(Jeon *et al.*, 2020). Fig. 9는 장면분류, 객체탐지, 의미론적 분할에 대한 차이를 시각화 하였다.



Fig. 9. Comparison of scene classification, object detection, and semantic segmentation (Kim et al., 2019)

AlexNt, VGG 등 영상의 분류에 주로 이용되는 층이 깊은 모델은 의미론적 분할에 적합하지 않다. 그 이유는 분할(segmentation)의 목적은 원본 이미지의 각 화소에 대해 클래스를 구분하고 객체와 배경을 분할하는 것으로 위치정보가 매우 중요한 요소로 작용하는데, 해당 모델들은 파라미터(parameter)의 개수와 차원을 축소하는 층을 가지고 있으므로 자세한 위치 정보를 잃게 된다. 그뿐만 아니라 해당 모델들의 마지막 층인 전결합계층에 의해 위치에 대한 정보를 잃는다. 의미론적 분할에 주로 이용되는 네트워크인 FCN, SegNet, U-Net 등은 이러한 문제를 해결하기 위해 인코더(encoder) & 디코더(decoder) 구조를 가지고 있다. 인코더의 주목적은 영상의 차원을 축소함으로써, 적은 메모리로 깊은 convolution을 수행할 수 있게 하는 것이다. 이 과정에서 분류에 이용되는 전결합계층을 1×1 컨볼루션 계층으로 간주하는 수정을 통해 위치 정보를 유지할 수 있다. 디코더는 인코더를 통해서 받은 결과의 차원을 늘려서, 입력 영상과 같은 차원으로 만들어 주는 과정이다. 조사된 25편의 의미론적 분할 분야의 연구 중 가장 많이 이용된 모델은 의미론적 분할 분야 저널 중에서 12편을 차지하고 있는 U-Net으로, U-Net 모델의 네트워크 구조는 Fig. 10과 같다.




Fig. 10. Architecture of U-Net network (Ronneberger et al., 2015)

U-Net은 2015년 생의학 분야에서 의미론적 분할을 목적으로 제안된 FCN 기반의 모델이다. 생의학 영상 분할을 위해 개발되었지만 적은 정보로 영상을 분할 가능한 장점으로 인해 원격탐사 분야에서 위성 영상을 이용한 토지피복분류에도 널리 사용되고 있다(Lee and Lee, 2020). 본 모델은 인코더와 디코더 구조로 구성되어 있다. U-Net의 모델 구조는 23개의 합성곱 층으로 구성되어 있다. U-Net의 인코더는 압축경로(contracting path)라고도 불리며, 고차원 형태의 이미지를 저차원 형태의 이미지로 변경시키면서 특징을 추출한다. 이후에는 인코딩된 영상을 다시 원래 형태로 변경해주는 확장경로(expanding path)라는 이름의 디코더 구조를 가지고 있다(Choi et al., 2020). U-Net은 압축경로에서 압축된 정보를 확장경로로 바로 연결하는 skip connection 기법을 적용하여 기존에 활용하지 못했던 위치정보를 사용할 수 있다는 장점이 있다(Ghosh et al., 2018). Park(2020)은 U-Net의 이러한 특징을 이용하여 위성영상을 이용한 산불피해영역 탐지 연구를 수행하였으며, 적은 수의 훈련데이터로도 성공적으로 산불 피해지역을 예측할 수 있다는 결론을 얻었다.

3.4 영상생성

앞서 설명한 장면분류나 의미론적 분할과 같은 분야는 모델에 학습된 데이터를 이용하여 영상 내에서 대상을 판별하는 분야에 속한다. 그에 반해 영상생성은 학습데이터를 이용하여 학습을 시켜주면, 특별한 클래스를 부여하지 않아도 모델 스스로 데이터 속의 정보를 찾아내서 새로운 데이터를 만들어 내는 기법을 말하며, 조사한 60편의 논문 중 5편을 차지하고 있다. 영상생성 분야에서 대표적으로 많이 이용되는 알고리즘은 Goodfellow et al. (2014)에 의해 처음 소개된 GAN이다. 해당 알고리즘의 최종 목표는 모델이 데이터셋과 유사한 이미지를 만들도록 하는 것으로, 원격탐사 분야에서는 저

해상도 영상을 이용하여 고해상도 이미지를 생성하는 초해상화(super-resolution) 연구에 주로 이용되고 있다. Fig. 11은 GAN 네트워크의 작동방식에 대한 설명이다.




Fig. 11. Architecture of GAN network

GAN은 위의 그림과 같이 생성자(generator)와 판별자(discriminator)로 구성되어 있다. GAN은 생성자와 판별자가 서로 적대적인 방향으로 모델의 학습을 수행해나가는 것이다. 그러므로 판별자는 생성자가 만드는 영상이 참인지 거짓인지에 대한 판별을 하는 방향으로, 생성자는 판별자를 속이는 방향으로 학습을 수행한다. 최종적으로는 생성자는 참인지 거짓인지 구별할 수 없는 수준의 데이터를 만들어 내고, 판별자 역시 판단 능력이 점차 개선되게 하는 것이 본 모델의 최종 목표이다.

2014년 이후로 GAN 모델의 영상생성 기술이 주목받으면서, 연구자들에 의해 다양한 연구가 수행되었다. DCGAN (Deep Convolutional Generative Adversarial Networks) 모델이 개발되기 전에는 GAN만 이용했을 경우 성능이 좋지 않다는 한계점이 존재하였다. 생성자와 판별자가 균형 있게 훈련을 주고받아야 학습이 안정적으로 이뤄질 수 있다. GAN 모델을 개발한 Goodfellow *et al.*(2014)에 의하면 두 모델은 적대적인 관계로 설정되었기에 학습이 불안정하고, 생성자와 판별자의 학습능력에서 차이가 발생할 경우 훈련이 한쪽에 치우쳐 성능이 저하되는 문제가 발생한다고 지출하였다. 이 문제를 해결한 DCGAN은 GAN에 CNN의 기술을 접목하여 성능향상을 이끌어낼 수 있었다(Radford *et al.*, 2016). 또한 지속적으로 GAN에 대한 연구가 수행되어 학습과정에서 기존 GAN에 비해 안정적이고, 더 고화질의 이미지를 생성할수 있는 EBGAN (Energy Based Generative Adversarial Networks) (Zhao *et al.*, 2016), 판별자의 학습을 안정화 시키는 방법으로 spectral normalization 방법을 제안하여 연산의 효율화와 학습의 안정화를 이끌어낸 SNGAN (Spectral Normalization for Generative Adversarial Networks)(Miyato *et al.*, 2018) 등 GAN 모델에 대한 지속적인 연구가 진행되고 있다.

4. 원격탐사 활용 분야에 따른 딥러닝 연구 동향 분석

4장에서는 본 논문에서 수집한 국내 논문들을 원격탐사의 활용 분야에 따른 연구 동향 분석을 수행하였다. 그 결과, 영상분류 분야의 연구가 28편으로 전체의 절반가량을 차지하였으며, 객체탐지 20편, 영상융합 7편, 변화탐지 3편, 기타 연구 4편이 수행된 것을 확인하였다. 아래에서는 원격탐사 활용 분야별로 적용된 딥러닝 연구기법이나 특징에 대해 요약하고, 해당 분야의 발전 현황에 대해 서술하였다.

4.1 영상분류

영상분류의 경우 토지피복분류를 수행한 연구가 가장 많았다. 위성영상, 항공사진과 같은 원격탐사 데이터는 넓은 지역의 정보를 신속하게 추출 가능한 장점이 있어 광범위한 지역의 토지피복 분류에 적합하다(Park *et al.*, 2001). 연구에 이용된 딥러닝 모델은 기본적인 CNN과 함께 2D CNN, 3D CNN, U-Net, SegNet, DeepLab, VGG-16, GoogLeNet 등의 다양한 네트워크가 이용되었다(Song and Kim, 2017; Lee and Kim, 2019; Choi *et al.*, 2020; Lee and Lee, 2020; Won *et al.*, 2020; Kim *et al.*, 2021; Lee *et al.*, 2018; Lee and Lee, 2021). 2차원 공간 특징을 이용하는 2D CNN과 3차원의 시공간 특징을 이용하는 LSTM (Long Short Term Memory)을 결합한 2DCBLSTM을 적용하여 기존 딥러닝 모델에 비해 높은 토지피복분류 정확도를 도출하였다(Kwak *et al.*, 2019). PCA (Principle Component Analysis) 차원축소를 초분광 영상에 적용하여 이를 딥러닝 모델에 적용했을 때, 원영상을 활용한 CNN 분류 결과보다 좋은 정확도를 나타내었고, 학습 시간 역시 단축시킬 수 있음을 확인한 연구가 있었다(Kwak *et al.*, 2019). 또한 SVM, ANN 등의 기계학습 기법과 DNN의 성능을 비교한 연구도 있었으며(Moon *et al.*, 2020), SVM과 GoogLeNet을 함께 이용하여 분류를 수행한 연구도 있었다(Kim *et al.*, 2020). 이렇듯 주제는 토지피복분류로 동일하지만, 각각의 연구에서 이용된 딥러닝 모델들이 상이한 것을 확인하였다. 토지피복분류와 유사한 기법을 이용하여 수행되지만 토지피복분류에 비해 소규모이고, 농경지역을 대상으로 하는 작물분류 연구도 다수 수행되었음을 확인하였다(Kim *et al.*, 2018; Choi *et al.*, 2020; Kwak *et al.*, 2019; Park *et al.*, 2019; Seong *et al.*, 2021). 식생의 층위구조를 추정하기 위해 광학영상과 LiDAR 영상을 융합활용 함으로써, 높은 정확도의 식생의 수고를 취득하였다(Cha *et al.*, 2020). 수계탐지(Jeon *et al.*, 2020)와 구름탐지(Seong *et al.*, 2020), 농

정지의 야적퇴비 탐지 연구(Kim *et al.*, 2021) 등은 관심 객체를 탐지하는 것이 목적이긴 하나, 탐지하고자 하는 대상의 형상이 건물, 자동차와 같이 뚜렷하지 않아 영상분류에 포함하였다. Jeon *et al.* (2020)에 의해 수행된 수계탐지의 경우 SAR영상과 모풀로지 Open연산을 거친 SAR영상, 수치표고 모델(DEM: Digital Elevation Model), 곡률 4종류의 데이터를 여러가지 케이스로 조합하여 각각의 케이스에 대한 딥러닝 모델을 학습시킨 후 수계탐지 결과를 도출하였다. Jeon *et al.* (2020)은 SAR 자료를 이용한 북극해 해빙분류 연구도 수행하였다. 해당 연구 또한 다양한 케이스로 해빙분류를 수행하였다. Seong *et al.* (2020)에 의해 수행된 구름탐지 연구는 구름탐지 밴드가 있는 위성영상을 이용해 학습한 딥러닝 모델을 구름탐지 밴드가 없는 위성영상에 적용하여, 구름탐지를 수행하기도 하였다. 또 다른 분류 연구로는 LCZ (Local Climate Zone) 분류체계를 이용하여 지표면 온도와 도시열섬 분석을 수행한 연구도 있었다. 해당 연구에서는 LCZ 분류에 CNN 모델을 이용하여 수원시와 대구광역시에 대한 분류를 수행하였다(Lee *et al.*, 2021). 네트워크를 수정하여 정확도를 개선한 연구도 있었다. SegNet인코더 부분을 ResNet으로 대체하여 검출 정확도를 개선한 획단보도 영역 검출 연구(Liang and Seo, 2021), 교량의 구성요소에 대한 자동분류를 목적으로 GoogLeNet의 inception 모듈과 ResNet의 residual 연결을 혼합하여 네트워크의 계층을 164개로 구성한 네트워크를 이용한 연구(Lee *et al.*, 2020)가 있었다. 두 개의 네트워크를 혼합하여 이용함으로써, 기존의 계층 증가에 따른 문제를 해결하였고 성능 또한 향상된 것을 확인하였다. 모바일매핑시스템을 이용하여 취득한 포인트 클라우드를 이용하여 포인트 클라우드 학습이 가능한 PointNet을 통해 연구지역의 차선의 색상을 분류하는 연구(Choi and Kim, 2021)도 있었다.

딥러닝 기반 영상분류 연구 동향 분석결과 분명한 한계점과 발전이 필요한 방향에 대해 파악할 수 있었다. 한계점으로는 데이터의 신뢰도에 대한 문제가 있다. 토지피복분류의 경우와 같이 공공기관에서 제안한 분명한 분류 기준이 확립되어 있는 경우나, 해빙 분류나 야적퇴비분류와 같이 관심 영역과 비 관심 영역 간의 구분이 확실할 경우에는 학습데이터의 품질에 신뢰도 문제가 없다고 판단할 수 있다. 반면에 식생의 층위 구조 분류, 구름탐지와 같이 학습데이터의 라벨링 과정에 기준이 불확실하거나 연구자의 주관적 의견이 포함될 경우, 라벨링 데이터의 품질에 일관성을 유지하기 어려운 문제점이 있을 것으로 사료된다. 영상분류 분야에서는 토지피복분류 연구와 더불어 다양한 데이터가 융합활용된 연구가 많은 것을 확인하였다. 선행 연구를 토대로 각 데이터가 가진 단점

의 상호보완이 가능한 데이터를 융합활용 할 경우 현재보다 다양한 주제의 연구 수행이 가능할 것으로 사료된다. 이와같이 데이터의 융합활용은 딥러닝의 발전을 위해 필수적인 요소로 작용하여 향후에도 많은 연구가 필요할 것으로 판단된다.

4.2 객체탐지

객체탐지에 딥러닝을 적용한 연구의 경우 영상 내에 존재하는 건물탐지, 해양 폐기물탐지, 차량탐지 등 확실한 형상이 지정된 물체의 탐지를 목표로 연구가 수행된 것을 확인하였다. 연구에는 Mask R-CNN, SSD, YOLO 등의 객체탐지 딥러닝 네트워크가 주로 사용되었으나, U-Net, HRNetV2, ResNet 등 분류, 의미론적분할에 이용되는 딥러닝 네트워크 또한 이용되었음을 확인하였다. 딥러닝 기반의 차량번호 인식 프로그램을 개발한 연구에서는 SSD 네트워크를 이용하여 차량 및 번호판 영역을 검출한 후 딥러닝 기반의 CNN 알고리즘을 적용하여 차량번호를 검출한 후 정확도 평가를 수행하였다(Lee *et al.*, 2020). 이때 네트워크의 계산속도 향상을 위해 CNN의 backbone 네트워크로 Mobilenet v2를 이용하였다(Sandler *et al.*, 2018). 이와 비슷한 주제의 연구로 딥러닝을 이용하여 간판의 영역을 자동으로 추출하는 것을 목표로 판류형 간판의 인식을 수행한 논문이 있었다(Kwon and Kim, 2019). 해당 논문에서는 Faster R-CNN을 이용하였으며, 간판인식의 정확도 향상을 위해 색상분류 방법론, 경계선 추출 방법론 등 다양한 방법론을 적용하였다. 소나무재선충병 감염 의심목을 효율적으로 탐지하기 위한 연구도 진행되었다(Lim and Do, 2021). 해당 연구에서는 분할방법인 SegNet과 검출방법인 YOLOv2를 이용하여 두 모델간의 정확도 비교를 수행하였다. 달 표면의 크레이터 자동 탐지를 목표로 수행된 연구도 있었다(Shin and Hong, 2018). 이 연구를 통해 NASA에서 인력에 의해 정의한 크레이터 정보의 오류에 대한 자동 보정이 가능하고, 크기분포 특성 및 발생 빈도 분석이 가능할 것으로 판단하였다. 딥러닝 기반 객체탐지 연구 동향 분석 결과를 요약하자면, 다양한 네트워크를 이용하여 객체탐지를 수행하였고 대부분의 연구결과에서 높은 탐지 정확도를 나타냈음을 알 수 있었다. 객체탐지 분야에서는 차량의 번호판 인식과 같은 연구에서 실시간 고속 탐지가 가능해야 하므로 탐지 정확도와 함께 네트워크 실행 속도가 중요한 요소로 인식되고 있다. 연구자들에 의한 지속적인 네트워크 개발을 통해 객체탐지 정확도와 속도의 향상이 가능할 것으로 판단된다.

4.3 영상융합

영상융합 분야에서는 초해상화 연구가 다수 수행되었다. 초

해상화는 저해상도 영상을 고해상도 영상으로 변환하는 기법을 말한다(Park *et al.*, 2003). 최근에는 초해상화 연구에 딥러닝 기술을 적용하는 연구가 많이 수행되고 있다. 초해상화의 경우 데이터가 합성곱층을 지나면서 공간적 특성을 유지하는 것이 중요하다. CNN 기반의 초해상화 네트워크인 DRNet (Dilated Residual Network)을 제안한 연구(Choi *et al.*, 2020)는 팽창된 잔차 합성곱신경망을 이용하여 수행되었기에, 같은 커널 내의 변수로도 멀리 떨어진 화소와의 공간적 특성의 반영이 가능하다. 이러한 장점으로 인해 실험 결과 성공적으로 해상도를 향상시킬 수 있음을 확인하였다. CNN을 이용한 또 다른 초해상화 연구로는 GAN 모델 구조를 활용하여 생성자에 DBPN (Deep Back Projection Network)를 이용하였다 (Choi *et al.*, 2020). 해당 연구에서는 초해상화에 적합한 손실 함수를 제안하고, 원본 영상을 활용한 딥러닝 모델 학습에 요구되는 학습데이터 구축 방법론을 제안하는 등 네트워크 성능향상을 위한 다양한 시도가 이루어졌다. 이를 통해 타 기법보다 초해상화 결과영상에서 고주파수 정보를 복원하는데 뛰어난 효과를 보였음을 확인하였다. 초해상화 이외에도 영상융합 분야에서 다양한 연구가 수행되었다. 대표적으로 CycleGAN을 활용한 항공영상 학습데이터셋 보완 기법에 관한 연구가 있었다(Choi *et al.*, 2020). 딥러닝은 학습데이터가 부족할 경우 정확도가 저하되는 문제가 발생한다. 이 문제를 해결하기 위해 해당 논문에서는 CycleGAN을 이용하여 오버샘플 영상 학습데이터를 구축하고, 품질을 평가함으로써 추가적 학습데이터셋으로 활용하기 위한 실험을 수행하였다. 결과적으로 CycleGAN을 이용하여 오버샘플 학습데이터를 생성하는 기법은 딥러닝 성능에 중요한 학습데이터의 양을 획기적으로 보완할 수 있으므로 초기 데이터가 부족할 경우에 효과적인 방법인 것을 확인하였다. 다른 Cycle GAN을 이용한 연구로는 SAR 영상의 색상 구현 방법에 대한 연구가 있었다 (Ku and Chung, 2018). 해당 연구에서는 기존 Cycle GAN의 성능을 개선하고자 다중 크기 식별자를 적용하여 MS Cycle GAN을 제안하였다. 이후 SAR와 광학영상이 포함되어 있는 데이터셋을 학습하여 기존의 Cycle GAN과 제안기법이 생성한 영상을 비교, 분석하였다. 결과적으로 제안기법에서 생성자 및 식별자 손실의 감소를 확인하였고, 각 영역의 특성에 부합하는 색상이 구현된 것을 확인하였다. 영상융합에서 GAN 모델뿐만 아니라 VAE (Variational Auto Encoder) 모델을 이용한 연구도 있었다(Baek and Yom, 2019). 해당 연구에서는 위성영상과 지상 관측소의 정보를 함께 이용하여 PM10 농도 데이터의 시공간 해상도 향상 딥러닝 모델 설계하였다. 위성영상과 지상 관측값 사이의 회귀 계수를 통해 PM10 관측값의

공간 해상도를 향상시켰으며, MLP를 이용하여 관측값의 시간 해상도를 향상 시켰다. 이후 LSTM을 이용하여 시간 해상도가 향상된 관측값을 예측하고, Conditional VAE를 이용하여 15분 단위의 시간 해상도와 30×30m의 공간 해상도를 가진 예측 영상을 성공적으로 생성하였음을 확인하였다. 딥러닝 기반의 영상융합 연구는 초해상화를 주제로 한 연구가 다수 수행되었음을 확인하였다. 그뿐만 아니라 학습데이터의 생성 혹은 높은 정확도의 정사영상 생성이 가능한 것을 확인하였다. 아직은 초기 연구단계이기 때문에 실제 연구에 생성된 학습데이터를 적용하기는 힘든 실정이다. 향후 연구를 통해 고품질의 데이터 생성이 가능해진다면 현재의 딥러닝의 한계점인 학습데이터가 적은 경우 결과값이 부정확한 것을 해결하고, 상대적으로 적은 양의 초기 학습데이터를 이용해서 높은 정확도의 결과를 도출할 수 있을 것으로 판단된다.

4.4 변화탐지

변화탐지는 원격탐사의 주요 연구 분야이며, 서로 다른 시기에 취득된 영상을 이용하여 동일한 지역에서 발생한 공간 및 분광 변화를 분석하여 자연재해로 인한 피해지역 검출, 식생 및 도심지 모니터링 등에 활용되는 기술이다(Han *et al.*, 2017). 이렇듯 변화탐지는 서로 다른 시기에 취득된 영상의 사용이 필수적이기 때문에 시계열 데이터를 처리할 수 있어야 한다. 기존에 많은 연구자에 의해 이용되었던 CNN의 경우 구조 내에서 시계열 정보를 처리할 수 없는 단점이 있다. 이러한 이유로 인해 변화탐지에 딥러닝을 적용하는 연구의 경우 딥러닝 기법 중 시계열 자료를 처리할 수 있는 네트워크인 LSTM 네트워크를 이용하였다(Song *et al.*, 2019). LSTM 외에도 SPADE 기반의 U-Net이 이용된 딥러닝을 적용한 변화탐지 연구 사례도 있었다(Song *et al.*, 2020). 해당 연구에서는 SPADE 기반 U-Net을 학습시켜, 기존의 네트워크와는 다르게 공간정보를 잃지 않고 유지할 수 있는 장점이 있다. 결과적으로 제안기법은 기존 U-Net이나 U-Net의 성능을 개선한 U-Net++에 비해 높은 성능을 확인할 수 있었다. 의미론적 분할에 이용되는 딥러닝 네트워크 외에, 객체탐지에 이용되는 딥러닝 네트워크를 이용하여 변화탐지를 수행한 연구도 있었다(Seong *et al.*, 2021). 해당 연구에서는 딥러닝 모델을 이용하여 위성영상에서 관심객체를 탐지하고, 이를 활용하여 다시기 위성영상 내의 객체 변화를 분석하고자 하였다. 해당 연구는 end-to-end 방식의 변화탐지에 최적화된 딥러닝 모델은 아니지만, 객체탐지 모델을 이용하여 변화탐지 연구의 수행이 가능함을 확인할 수 있었다. 요약하자면 변화탐지에 딥러닝 기술의 접목을 통해, 특정 화소를 중심으로 커널 내의 주변

화소와의 관계를 반영하여 학습이 가능해졌다(Zhang *et al.*, 2019). 이는 기존 화소기반 변화탐지기법과 객체기반 변화탐지 기법에서의 장점들을 한 번에 얻을 수 있었음을 의미한다. 또 의미론적 분할에 이용되는 네트워크나 객체탐지에 이용되는 네트워크들이 변화탐지라는 분야에 함께 적용될 수 있음을 확인하였다. 이를 통해 향후 수행될 딥러닝을 적용한 변화탐지연구에 다양한 종류의 네트워크 적용이 가능할 것으로 판단되고, 변화탐지 정확도 또한 지속적인 연구를 통해 향상될 것으로 사료된다.

4.5 기타

위의 영상분류, 객체탐지, 변화탐지, 영상융합 외에도 다양한 분야의 연구에서 딥러닝이 활용되었다. Lee *et al.*(2020)은 VAE를 활용한 교량 손상 위치 추정방법을 제안하였다. 해당 연구에서는 손상 위치 추정 문제를 해결하고자 VAE를 기반으로 한 신호 군집화의 가능성을 이론적으로 확인하는 데 중점을 두었다. 초기에는 여러 분포를 보이던 각 신호들이 Epoch가 커질수록 하나의 분포로 통일되는 것을 확인하였다. 신호의 군집화를 이용하여 계측되는 신호가 어떤 군집에 속하는지 파악한다면 교량의 손상 유형을 파악할 수 있게 되기에 성공적인 결과를 얻었다고 판단하였다. 이 외에도 GIS 데이터와 기상데이터를 함께 이용하여 LSTM-RNN 기법을 통해 태양광 발전 시설의 적지 분석을 수행한 연구(Heo *et al.*, 2020), Landsat 8 영상과 기상청의 기상데이터를 함께 이용하여 DNN 기반으로 지표면 온도를 산출한 연구(Kim *et al.*, 2020)와 SAR 영상과 다양한 GIS 및 기상자료를 DNN에 학습시켜 고해상도 해상풍 지도를 작성한 연구도 있었다(Joh *et al.*, 2021). 이를 통해 위성영상 뿐만 아니라 DSM, 기상데이터 등 다양한 공간정보 또한 딥러닝에 이용되고 있는 것을 확인하였다.

5. 원격탐사 영상 취득 탑재체별 딥러닝 연구 동향 분석

위성, 드론, 항공기 등 원격탐사 센서 탑재체별 딥러닝 연구 동향 조사를 실시하였다. 분류 결과, 위성으로부터 취득된 영상을 이용한 연구가 25편으로 대다수를 차지하였으며, 드론 영상 관련 연구 11편, 항공사진 관련 연구 11편, MMS를 포함한 기타 자료를 이용한 연구가 15편 수행되었다. 활용할 수 있는 위성의 수와 스펙이 다양한 만큼, 다양한 목적의 딥러닝 연구가 위성영상을 이용하여 수행되었다. 라벨링 데이터를 직접 구축하여 의미론적 분할기반으로 농경지를 분류

하거나 토지 피복도 분류 및 객체탐지를 수행하였다(Choi *et al.*, 2020; Lee and Lee, 2020; Song *et al.*, 2020). Imagenet으로 사전학습된 데이터를 이용하여 fine tuning 과정을 거친 뒤 Kompsat-3A위성 영상을 이용하여 모델을 학습시켜, CNN 기반의 DeepLab 모델을 이용한 의미론적 분할을 수행하여 토지피복도를 생성하기도 하였다(Rhee *et al.*, 2018). 토지피복분류를 수행하기 위해 환경부의 토지피복도(Kim *et al.*, 2021) 혹은 EuroSAT 토지피복 데이터를 활용하기도 하였다(Jo *et al.*, 2019). Landsat QA 밴드를 이용하여 훈련자료를 구축한 후 PlanetScope 기반 구름탐지를 수행하였으며, DeepLab-v3 기반의 의미론적 분할기법을 알고리즘으로 활용하였다(Seong *et al.*, 2020). GAN 기반의 초해상화(Choi *et al.*, 2020)나 다중센서 영상 간 융합(Choi *et al.*, 2020)을 수행하는 연구도 진행되었다. 그 외 변화탐지(Song *et al.*, 2019; Song *et al.*, 2020; Seong *et al.*, 2021), 녹조 분류(Kim *et al.*, 2020), 지표면 온도 산출(Kim *et al.*, 2020) 등에 딥러닝 기법이 활용되기도 하였다. 위성영상을 활용한 딥러닝 연구에 사용된 데이터는, 대부분이 직접 훈련데이터를 구축하였으나, GIS 데이터나 항공사진 기반으로 구축된 라벨링 데이터(ISPRS 항공사진 오픈소스 데이터) 이용 및 전이학습을 수행하기도 하였으며, QA 밴드와 같은 ARD 자료를 이용하여 훈련자료를 구축하기도 하였다.

항공사진을 이용한 연구의 대부분은 의미론적 분할을 딥러닝 목표로 수행을 하였다. 건물/비건물의 이진 분류나 농작물 분류, 토지피복 분류 등을 목표로 하였다. U-net 기반의 항공사진 내 누락오류를 탐지하고 영역을 복원하기 위한 연구 또한 수행되었다(Wi *et al.*, 2020). 사용된 딥러닝 모델은 SegNet, U-net, FC-DenseNet, HRNetV2 등을 활용하였고, 개체분할이 가능한 Mask R-CNN을 활용하였다. 분류기반 딥러닝 모델을 적용한 연구도 다수 수행되었다. 항공초분광 영상을 이용하여 농경지 4개의 클래스와 도심지 6개의 클래스로 분류를 수행한 연구가 대표적이다(Song and Kim, 2017). 그 외에 항공사진에 GAN을 적용한 연구로, 항공 영상 학습데이터 셋을 보완하기 위한 연구(Choi *et al.*, 2020)와 항공 라이다 영상과 항공 적외선 영상을 대상으로 염밀정사영상을 생성하기 위한 논문도 있었다(Shin *et al.*, 2020).

드론 연구는 항공사진을 이용한 연구와 마찬가지로 대부분 분류나 의미론적 분할기반 영상분류에 초점을 맞춰서 진행되고 있었으며, 차이점으로는 객체를 탐지하기 위한 연구가 다수 수행되었다. 예를 들어 교통량을 분석하기 위한 차량 탐지(버스, 승용차, 트럭)(Park *et al.*, 2020), 해안 표착 폐기물 탐지(Bak *et al.*, 2020), 차량 및 차량 번호판영역 탐지(Lee,

2020), 산불 위해요소(산불, 연기, 차량, 건물, 사람, 무덤) 탐지 (Chung *et al.*, 2020), 작물분류(Kim *et al.*, 2018; Choi *et al.*, 2020) 등을 목적으로 연구가 진행되었다. 해당 연구에서는 산불탐지를 위해 드론 영상과 인터넷 자료를 모두 사용하여 라벨링을 수행하기도 하였다. 오픈소스데이터를 활용한 사례보다는 대부분 라벨링 데이터를 직접 구축하여 연구에 활용한 경우가 대다수였음을 확인하였다. 위성영상과 항공사진, 드론 영상을 이용하여 딥러닝 연구를 수행한 연구들을 비교·분석하여 Table. 1에 정리하였다.

기타 플랫폼을 이용한 딥러닝 연구로, 나무를 폐색영역으로 선정하여 maskRCNN 기반 탐지를 하였으며, 구글스트리트 캡쳐 영상과 아이폰 카메라 영상을 이용하여 라벨링을 수행하기 위한 훈련자료로 활용하였다(Lee *et al.*, 2019). 카메라를 이용하여 촬영된 콘크리트 벽면의 균열을 탐지하는 연구도 수행되었다(Kim *et al.*, 2018; Kim *et al.*, 2019). 영상이 아닌 GIS 데이터를 이용하여 태양광 발전량 추정 및 태양광 발전 시설 적지 선별하기 위한 연구 또한 진행되었다(Heo *et al.*, 2020). 분할, 탐지 딥러닝 기법을 함께 활용한 연구로는, Mobilenet-SSD와 U-Net을 이용하여 도로균열 탐지 시스템

을 개발한 연구(Ha *et al.*, 2021)와 MMS (Mobile Mapping System) 기반 오픈소스 데이터를 이용하여 SegNet과 ResNet을 조합한 딥러닝 기반 획단보도 영역 검출 연구(Liang and Seo, 2021)가 수행되었다. 또 다른 MMS 자료를 활용한 연구로는 전용 스캐너와 카메라 장비를 이용하여 도로 이미지를 취득한 후, 차선을 포함한 도로 지면을 추출하는 연구가 수행된 바 있다(Choi and Kim, 2021).

영상 취득 탐재체 별로 정리하여 분석함으로써, 취득 센서가 가지고 있는 특징에 따라 수행되는 연구가 달라짐을 파악할 수 있었다. 위성영상의 경우 넓은 지역에 대한 영상을 빠른 주기로 취득할 수 있는 장점으로 인해 토지피복분류나 변화 탐지와 같은 연구가 많이 진행되었다. 드론 영상이나 항공사진의 경우 위성영상만큼 넓은 지역을 포함하지 못하지만, m급의 고해상도 혹은 cm급의 초고해상도 영상 취득이 가능하다. 이런 장점으로 인해 의미론적 분할이나 분류 연구보다 객체탐지 분야에 초점을 맞춰 이용된 것을 확인하였다. 그뿐만 아니라 광학 영상뿐만 아니라 LiDAR 자료 혹은 적외선 자료도 딥러닝에 적용할 수 있음을 알 수 있었다. 반면, 사용된 딥러닝 네트워크의 경우 영상의 특성에 따른 차이보다는 장면분류,

Table. 1. Comparison of deep learning research according to the remote sensing platforms

Platform	Aircraft	UAV	Satellite
Main Research Field	<ul style="list-style-type: none"> - Research mainly related to land-cover classification (urban and agricultural areas) - A few research related to building detection, data, augmentation, ortho image generation, etc. 	<ul style="list-style-type: none"> - Research mainly related to land-cover classification and object detection - Diverse object detection targets e.g., vehicles, vehicle license plate, coastal waste, forest fire hazard (wildfire, smoke, vehicle, building, person, grave), etc. 	<ul style="list-style-type: none"> - Relatively much research conducted - Diverse topics e.g., image classification, cloud detection, image fusion, super resolution, surface temperature estimation, change detection, etc. - Many studies such as change detection conducted due to easy accessibility of time-series satellite images
Training Dataset Construction	<ul style="list-style-type: none"> - Mainly using open source data such as ISPRS labeling data, digital map, GIS data, etc. 	<ul style="list-style-type: none"> Mostly using self-generated training data Directly generating labeling data from images downloaded from internet 	<ul style="list-style-type: none"> - Building training data using QA band or UDM provided together with satellite images - using aerial image-based open source labeling data by applying transfer learning
Used Deep Learning Network	<ul style="list-style-type: none"> - Different deep learning networks used according to the purpose of the study rather than the difference of the platforms - Scene classification : 2D CNN, 3D CNN, SENet, Alexnet, GoogLeNet, ResNet - Object detection : YOLO, MaskRCNN - Semantic segmentation : SegNet, U-net, FC-DenseNet, HRNetV2, DeepLabV3+ 		

의미론적 분할, 객체탐지 등 연구의 수행 목적에 따라 달라진다는 것을 확인하였다.

6. 딥러닝 훈련을 위한 오픈소스 데이터

최근 영상처리 분야에서 딥러닝 기술이 각광받으면서, IT 기업, 대학교, 연구소 등에서 제작한 딥러닝에 적합한 오픈소스 데이터셋이 연구자들에게 온라인을 통해 무료로 제공되고 있다. 본 연구에서는 현재 제공 중인 오픈소스 데이터셋들을 이용 목적에 따라 분류를 수행하였다. 본 논문에서 언급된 오픈소스 데이터셋은 참고문헌의 하이퍼링크를 통해 다운로드 가능하다.

원격탐사 분야의 딥러닝 연구 중에 이용된 오픈소스 데이터로는, Mapping Challenge: Building Missing Maps with Machine Learning 데이터를 이용하거나(Lee *et al.*, 2018), 독일 사진측량, 원탐 및 공간정보 학회(DGPF)가 구축하고 ISPRS가 제공하는 항공 적외선 정사영상(IR-R-G밴드), LiDAR 영상 및 라벨데이터를 이용하여 건물을 탐지하는 연구(Cho and Lee, 2020)가 있었다. 다른 객체탐지 데이터셋으로는 CIFAR-10이 있다. 10개의 클래스로 구성된 대규모 데이터셋이며 해당 데이터셋을 이용하여 해상에 존재하는 객체 검출 고속화를 목표로 수행한 연구가 있다(Song *et al.*, 2020). 건물 용도 분류에는 국가 공간정보 포털에서 제공하는 GIS 건물통합정보 shp파일이 이용되었으며(Song and Kim, 2017), 항공사진, 수치지도 등 다양한 공간정보 데이터를 이용하기도 하였다(Lee *et al.*, 2018; Mo *et al.*, 2021). 우리나라의 공간 정보뿐만 아니라 미국의 공간정보를 이용한 연구도 있었다. Landsat-8 OLI 영상과 동일한 공간해상도에서 작물과 토지피복 정보를 제공하는 National Agricultural Statistics Service의 CDL (Cropland Data Layer) 자료를 학습 및 테스트 데이터로 이용하여 작물분류 연구에 이용하였다(Park *et al.*, 2019). 항공정사영상과 세분류 토지피복도를 이용하여 총 2000개의 훈련자료를 구축하기도 하였다(Lee and Kim, 2017). 산림 자원의 변화를 주기적으로 파악하기 위해 전 국토에 일정한 간격으로 구축되어있는 표본점 자료인 NFI (National Forest Inventory) 또한 딥러닝 연구에 활용된 바 있다(Park *et al.*, 2019). 미국 정부 오픈 데이터 플랫폼인 data.gov의 SPARCS (Spatial Procedures for Automated Removal of Cloud and Shadow) 구름 데이터셋을 이용하여 U-Net 모델의 학습을 수행하여 구름탐지를 수행한 연구도 있었다(Kang *et al.*, 2021). 해당 데이터셋에서는 구름 영상과 라벨링된 영상을 제공하고 있다. 이와 더불어 ILSVRC 대회에서 제공하는 Imagenet

데이터셋을 이용한 논문도 확인할 수 있었다. 본 데이터셋은 1400만개 이상의 이미지로 구성된 딥러닝용 학습 데이터셋이다. 하지만 공개되어있는 데이터셋은 1,000개의 클래스로 구성되며 100만여개 정도에 한정되어 있다. 본 논문에서 조사한 저널은 국내에 한정되어 있기에 총 2편이 Imagenet 데이터셋을 이용하였으나, 해외 연구자들의 경우 분류 문제에서 전이 학습 혹은 모델의 학습데이터로 Imagenet 데이터가 많이 이용되고 있는 실정이다(Lee *et al.*, 2018; Park *et al.*, 2019). 현재 다양한 오픈소스 데이터가 연구자들에게 무료로 제공되고 있지만, 해당 데이터셋들은 대부분이 큰 용량으로 구축되어 있다. 학습데이터가 많을수록 딥러닝 성과에 큰 차이가 있기 때문이다. 또한 딥러닝은 GPU를 기반으로 연산을 수행한다. 이는 딥러닝 연구를 수행하기 위해서는 고사양의 하드웨어가 장착된 컴퓨터가 필수적임을 의미한다. 향후 네트워크의 발전으로 네트워크 구조의 경량화를 통해 하드웨어 의존성을 낮출 수 있게 된다면, 현재보다 빠른속도로 딥러닝이 발전할 것으로 판단된다.

7. 요약 및 결론

본 논문에서는 국내의 원격탐사 분야에 적용된 딥러닝 논문 연구 동향 조사를 통해, 원격탐사 분야에서 딥러닝의 연구 동향 및 방법에 대한 전반적인 내용을 설명하였다. 조사한 60여 편의 논문을 바탕으로 딥러닝 네트워크 목적별, 원격탐사 활용 분야별, 원격탐사 영상 취득 탐색체별로 수행되고 있는 연구 동향에 대해 서술하였다. 마지막으로는 논문에서 훈련 자료 구축에 효과적으로 이용되었던 오픈소스 데이터를 정리하여 딥러닝 연구를 수행하는 연구자들에게 도움을 제공하고자 하였다.

현시기에 딥러닝 기술이 다양한 분야에서 활용되고, 기존 기법에 비해 뛰어난 효율성을 나타내는 만큼, 원격탐사 분야에서도 딥러닝 기술을 적용한 연구가 증가하는 추세를 보이고 있다. 하지만 딥러닝 기술이 원격탐사 분야에 자리 잡기 위해서는 해결해야 할 한계점도 분명히 존재한다. 대표적인 한계점으로는, 학습데이터의 품질에 따라 딥러닝 성과가 극명히 갈리는 문제가 있다. 앞서 언급하였듯이, 학습데이터의 신뢰도 확보를 위해서는 연구자의 주관적인 의견이 배제되어야 한다. 이를 위해서 연구 주제별로 적절한 기준의 확립을 통해 학습데이터의 표준화가 필요할 것으로 생각된다. 또한, 딥러닝을 접목한 연구를 수행하기 위해서는 고사양의 하드웨어가 필수적이다. 하드웨어가 급속도로 발전한 것은 사실이지만, 많은 양의 데이터를 처리하기 위해서는 현재에도 고사양이라고 불

리는 스페의 하드웨어가 필요한 실정이다. 이러한 이유로 인해 딥러닝 네트워크 구조의 경량화는 딥러닝에 있어 필수적인 요소라고 판단된다. 본 논문을 통해 딥러닝 연구 동향 분석을 수행함으로써, 딥러닝의 한계점과 더불어 딥러닝의 발전 방향 또한 파악하였다. 첫 번째로는 다양한 데이터의 융합 활용이 필요할 것으로 판단된다. 영상분류 분야에서 토지피복분류 연구와 더불어 다양한 데이터가 융합 활용된 연구가 많은 것을 확인하였다. 데이터를 융합하여 활용하는 경우 각 데이터가 가진 장·단점의 상호보완을 통해 단일 종류의 데이터를 이용하는 것 보다 다양한 주제의 연구 수행이 가능할 것으로 사료된다. 두 번째로, 딥러닝을 이용한 차량의 번호판 인식과 같은 연구에서는 실시간에 가까운 탐지가 가능해야 하므로 탐지 정확도와 함께 네트워크 실행 속도가 중요한 요소로 인식되고 있다. 연구자들에 의한 지속적인 네트워크의 발전을 통해 객체탐지 정확도와 속도의 향상이 가능할 것으로 판단된다.

현재까지 수행된 선행 연구들을 통해 딥러닝은 그 효율성을 입증하였다. 딥러닝 연구가 수행됨에 따라 기존의 네트워크가 수정, 보완을 통해 성능이 개선되고 있음을 확인하였다. 이러한 발전 추세에 따라 딥러닝 모델은 네트워크 구조를 심층화하고 연산량은 줄이면서 정확도는 향상할 수 있는 방향으로 발전해 나갈 것으로 판단된다. 또한, 딥러닝의 강력한 성능과 잠재력에 힘입어 많은 연구자가 원격탐사 분야에서 딥러닝을 활용한 연구를 지속적으로 수행할 것으로 기대한다. 본 논문을 통해 국내 원격탐사 분야에 적용된 딥러닝 연구의 동향을 분석함으로써, 현재 딥러닝이 해결해야 할 한계점을 파악하였다. 이와 더불어 원격탐사 분야에서 딥러닝의 활발한 활용을 위해 발전이 필요한 방향을 제시하였다. 향후에는 본 연구에서 조사한 논문들을 대상으로 딥러닝 네트워크별, 원격탐사 활용 분야별로 활용 데이터셋 및 정확도 평가지표를 고려하여 정확도 분석에 관한 연구를 추가적으로 진행할 계획이다. 이를 통해 향후 연구자들의 연구 방향을 설정하는 데 있어 도움을 제공할 수 있을 것으로 사료된다.

감사의 글

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2021R1A2C2093671). 이 논문은 2021년도 국토지리정보원의 ‘항공영상 품질검사 자동화체계 연구’사업의 지원을 받아 수행된 연구임.

References

- Back, C.S., and Yom, J.H. (2019), Spatiotemporal resolution enhancement of PM10 concentration data using satellite image and sensor data in deep learning, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 37, No. 6, pp. 517-523. (in Korean with English abstract)
- Bak, S.H., Kim, N.K., Jeong, M.J., Hwang, D.H., Unuzaya Enkhjargal, Kim, B.R., Park, M.S., Yoon, H.J., and Seo, W.C. (2020), Study on detection technique for coastal debris by using unmanned aerial vehicle remote sensing and object detection algorithm based on deep learning, *Journal of the Korea Institute of Electronic Communication Science*, Vol. 15, no. 6, pp. 1209-1216. (in Korean with English abstract)
- Cha, S.G., Jo, H.W., Lim, C.H., Song, C.H., Lee, S.G., Kim, J.W., Park, C.Y., Jeon, S.W., and Lee, W.K. (2020), Estimating the stand level vegetation structure map using drone optical imageries and LiDAR data based on an Artificial Neural Networks (ANNs), *Korean Journal of Remote Sensing*, Vol. 36, No. 5-1, pp. 653-666. (in Korean with English abstract)
- Cho, E.J., and Lee, D.C. (2020), Building detection by convolutional neural network with infrared image, LiDAR data and characteristic information fusion, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 38, No. 6, pp. 635-644. (in Korean with English abstract)
- Choi, H.S., Seo, D.C., and Choi, J.W. (2020), A pansharpening algorithm of KOMPSAT-3A satellite imagery by using dilated residual convolutional neural network, *Korean Journal of Remote Sensing*, Vol. 36, No. 5-2, pp. 961-973. (in Korean with English abstract)
- Choi, H.W., Lee, S.H., Kim, H.H., and Suh, Y.C. (2020), A study on the complementary method of aerial image learning dataset using cycle generative adversarial network, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 38, No. 6, pp. 499-509. (in Korean with English abstract)
- Choi, I.H., and Kim, E.M. (2021), Automatic construction of deep learning training data for high-definition road maps

- using mobile mapping system, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 39, No. 3, pp. 133-139. (in Korean with English abstract)
- Choi, S.K., Lee, S.K., Kang, Y.B., Choi, D.Y., and Choi, J.W. (2020), Use of unmanned aerial vehicle imagery and deep learning U-Net to classification upland crop in small scale agricultural land, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 38, No. 6, pp. 671-679. (in Korean with English abstract)
- Choi, S.K., Lee, S.K., Kang, Y.B., Seong, S.K., Choi, D.Y., and Kim, G.H. (2020), Applicability of image classification using deep learning in small area : case of agricultural lands using UAV image, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 38, No. 1, pp. 23-33. (in Korean with English abstract)
- Choi, Y.J., Kim, M.S., Kim, Y.W., and Han, S.H. (2020), A study of CNN-based super-resolution method for remote sensing image, *Korean Journal of Remote Sensing*, Vol. 36, No. 3, pp. 449-460. (in Korean with English abstract)
- Chung, D.K., Lee, M.H., Kim, H.Y., Park, J.Y., Lee, and I.P. (2020), Development of forest fire monitoring system using a long-term endurance solar powered drone and deep learning, *Journal of Korean Society for Geospatial Information Science*, Vol. 28, No. 2, pp. 29-38. (in Korean with English abstract)
- Ghosh, A., Ehrlich, M., Shah, S., Davis, L.S., and Chellappa, R. (2018). Stacked u-nets for ground material segmentation in remote sensing imagery. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops(CVPRW)*, 18-22 June, Salt Lake City, United States of America, pp. 257-261.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D.F., Ozair, S., Courville, A., and Bengio, Y. (2014). Generative adversarial nets. *Advances in neural information processing systems*, pp. 2672-2680.
- Ha, J.W., Park, K.W., and Kim, M.S. (2021), A development of road crack detection system using deep learning-based segmentation and object detection, *The Journal of Society for e-Business Studies*, Vol. 26, No. 1, pp. 93-106. (in Korean with English abstract)
- Han, Y., Kim, T., Han, S., and Song, J. (2017). Change detection of urban development over large area using KOMPSAT optical imagery. *Korean Journal of Remote Sensing*, Vol. 33. No. 6-3, pp. 1223-1232. (in Korean with English abstract)
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, Las Vegas, United States of America, pp. 770-778.
- Heo, J., Park, B.S., Jung, Y.H., Jung, J.H., Kim, B.Y., and Han, S.U. (2020), Searching of photovoltaic panel installation sites on highway network using LSTM RNN-based power output estimation, *Journal of Korean Society for Geospatial Information Science*, Vol. 28, No. 1, pp. 25-33. (in Korean with English abstract)
- Hinton, G.E. (2009). Deep belief networks. *Scholarpedia*, Vol. 4, No. 5, pp. 5947.
- Jang, Y.J. and Chung, D.W. (2019), Technology trend for image analysis based on deep learning, *Current Industrial and Technological Trends in Aerospace*, Vol. 17, No. 1, Korea Aerospace Research Institute, Daejeon, pp. 113-122.
- Jeon, E.I., Kim, S.H., Kim, B.S., Park, K.H., and Choi, O.I. (2020), Semantic segmentation of drone imagery using deep learning for seagrass habitat monitoring, *Korean Journal of Remote Sensing*, Vol.36, No.2-1, pp. 199-215. (in Korean with English abstract)
- Jeon, H.G., Kim, D.J., Kim, J.W., Vadivel, S.K.P., Kim, J.E., Kim, T.I., and Jeong, S.H. (2020), Selection of optimal band combination for machine learning-based water body extraction using SAR satellite images, *Journal of the Korean Association of Geographic Information Studies*, Vol. 23, No. 3, pp. 120-131. (in Korean with English abstract)
- Jeon, H.G., Kim, J.W., Vadivel, S.K.P., and Kim, D.J. (2019), A study on classifying sea ice of the summer arctic ocean using sentinel-1 A/B SAR data and deep learning models, *Korean Journal of Remote Sensing*, Vol. 35, No. 6-1, pp. 999-1009. (in Korean with English abstract)
- Jo, W.H., Lim, Y.H., and Park, K.H. (2019), Deep learning based land cover classification using convolutional neural network: A case study of Korea, *Journal of the Korean*

- Geographical Society*, Vol. 54, No. 1, pp. 1-16. (in Korean with English abstract)
- Joh, S.U., Ahn, J.H., and Lee, Y.W. (2021), Estimation of high-resolution sea wind in coastal areas using Sentinel-1 SAR images with artificial intelligence technique, *Korean Journal of Remote Sensing*, Vol. 37, No. 5-1, pp. 1187-1198. (in Korean with English abstract)
- Kang, J.G., Kim, G.A., Jeong, Y.M., Kim, S.Y., Youn, Y.J., Cho, S.B., and Lee, Y.W. (2021), u-net cloud detection for the SPARCS cloud dataset from landsat 8 images, *Korean Journal of Remote Sensing*, Vol. 37, No. 5-1, pp. 1149-1161. (in Korean with English abstract)
- Kim, A.R., Kim, D.H., Byun, Y.S., and Lee, S.W. (2018), Crack detection of concrete structure using deep learning and image processing method in geotechnical engineering, *Journal of the Korean Geotechnical Society*, Vol. 34, No. 12, pp. 145-154. (in Korean with English abstract)
- Kim, B.H., Kim, G.S., Jin, S.M., and Cho, S.J. (2019), A comparative study on performance of deep learning models for vision-based concrete crack detection according to model types, *Journal of the Korean Society of Safety*, Vol. 34, No. 6, pp. 50-57. (in Korean with English abstract)
- Kim, E.H., Kim, K.Y., Kim, S.M., Tingwei Cui, and Ryu, J.H. (2020), Deep learning based floating macroalgae classification using Gaofen-1 WFV images, *Korean Journal of Remote Sensing*, Vol. 36, No. 2-2, pp. 293-307. (in Korean with English abstract)
- Kim, J., Song, Y.H., and Lee, W.K. (2021), Accuracy analysis of multi-series phenological landcover classification using u-net based deep learning model – focusing on the seoul, republic of korea, *Korean Journal of Remote Sensing*, Vol. 37, No. 3, pp. 409-418. (in Korean with English abstract)
- Kim, N.K., Park, M.S., Jeong, M.J., Hwang, D.H., and Yoon, H.J. (2021), A study on field compost detection by using unmanned aerial vehicle image and semantic segmentation technique based deep learning, *Korean Journal of Remote Sensing*, Vol.37, No.3, 2021, pp. 367-378. (in Korean with English abstract)
- Kim, S. W., Kang, M. S., Song, J., Park, W. Y., Eo, Y. D., and Pyeon, M. W. (2020). Automatic classification of drone images using deep learning and SVM with multiple grid sizes. *Journal of the Korean Society of Surveying*,
- Geodesy, Photogrammetry and Cartography*, Vol. 38, No. 5, pp. 407-414.
- Kim, S.Y., Lee, S.J., and Lee, Y.W. (2020), Retrieval of land surface temperature using Landsat 8 images with deep neural networks, *Korean Journal of Remote Sensing*, Vol. 36, No. 3, pp. 487-501. (in Korean with English abstract)
- Kim, Y.S., Kwak, G.H., Lee, K.D., Na, S.I., Park, C.W., and Park, N.W. (2018), Performance evaluation of machine learning and deep learning algorithms in crop classification: impact of hyper-parameters and training sample size, *Korean Journal of Remote Sensing*, Vol. 34, No. 5, pp. 811-827. (in Korean with English abstract)
- Krizhevsky, A., and Hinton, G. (2009), Learning multiple layers of features from tiny images, *CIFAR-10/100*, <https://www.cs.toronto.edu/~kriz/cifar.html> (last date accessed: 13 November 2021).
- Krizhevsky, A., Sutskever, I., and Hinton, G.E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, Vol. 25, pp. 1097-1105.
- Ku, W.H., and Chung, D.W. (2018), The method for colorizing SAR images of KOMPSAT-5 using cycle GAN with multi-scale discriminators, *Korean Journal of Remote Sensing*, Vol. 34, No. 6-3 pp. 1415-1425.
- Kwak, G.H., Park, M.G., Park, C.W., Lee, K.D., Na, S.I., Ahn, H.Y., and Park, N.W. (2019), Combining 2D CNN and bidirectional LSTM to consider spatio-temporal features in crop classification, *Korean Journal of Remote Sensing*, Vol. 35, No. 5-1, pp. 681-692. (in Korean with English abstract)
- Kwak, T.H., Song, A.R., and Kim, Y.I. (2019), The impact of the PCA dimensionality reduction for CNN based hyperspectral image classification, *Korean Journal of Remote Sensing*, Vol. 35, No. 6-1, pp. 959-971. (in Korean with English abstract)
- Kwon, S.I., and Kim, E.M. (2019), Recognition of flat type signboard using deep learning, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 37, No. 4, 219-231. (in Korean with English abstract)
- LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition.

- Proceedings of the IEEE*, Vol. 86, No. 11, pp. 2278-2324.
- Lee, D.G., Cho, E.J., and Lee, D.C. (2018), Evaluation of building detection from aerial images using region-based convolutional neural network for deep learning, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 36, No. 6, pp. 469-481. (in Korean with English abstract)
- Lee, G.S. (2020), Illegal parking number recognition technology using deep learning algorithm based on drone image, *Journal of the Korean Cadastre Information Association*, Vol. 22, no. 3, pp. 20-31. (in Korean with English abstract)
- Lee, G.S., Kim, Y.J., and Koh, D.K. (2020), Development of vehicle number recognition program based on deep learning algorithm, *Journal of The Korean Cadastre Information Association*, Vol. 22, No. 1, pp. 124-135. (in Korean with English abstract)
- Lee, J.H. Park, J.J., and Yoon, H.C. (2020), Automatic classification of bridge component based on deep learning, *Journal of the Korean Society of Civil Engineers*, Vol. 40, No. 2, pp. 239-245. (in Korean with English abstract)
- Lee, J.M., Ham, S.W., Bae, K.H., and Park, H.K. (2019), Detection ability of occlusion object in deep learning algorithm depending on image qualities, *Journal of the Korean Association of Geographic Information Studies*, Vol. 22, No. 3, pp. 82-98. (in Korean with English abstract)
- Lee, K.H., Chung, M.W., Jeon, C.W., and Shin, D.H. (2020), Damage localization of bridges with variational autoencoder, *Journal of the Korean Society of Civil Engineers*, Vol. 40, No. 2, pp. 233-238. (in Korean with English abstract)
- Lee, S.H., and Kim, J.S. (2019), Land cover classification using semantic image segmentation with deep learning, *Korean Journal of Remote Sensing*, Vol. 35, No. 2, pp. 279-288. (in Korean with English abstract)
- Lee, S.H., and Lee, M.J. (2020), A study on deep learning optimization by land cover classification item using satellite imagery, *Korean Journal of Remote Sensing*, Vol. 36, No. 6-2, pp. 1591-1604. (in Korean with English abstract)
- Lee, S.H., and Lee, M.J. (2021). A study of establishment and application algorithm of artificial intelligence training data on land use/cover using aerial photograph and satellite images, *Korean Journal of Remote Sensing*, Vol. 37, No. 5-1, pp. 871-884.
- Lee, Y.S., Lee, S.W., Im, J.H., and Yoo, C.H. (2021), Analysis of surface urban heat island and land surface temperature using deep learning based local climate zone classification: A case study of suwon and daegu, korea, *Korean Journal of Remote Sensing*, Vol. 37, No. 5-3, pp. 1447-1460. (in Korean with English abstract)
- Liang Han, and Seo, S.Y. (2021), Detection of zebra-crossing areas based on deep learning with combination of SegNet and ResNet, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 39, No. 3, pp. 141-148. (in Korean with English abstract)
- Lim, E.T. and Do, M.S. (2021), Pine wilt disease detection based on deep learning using an unmanned aerial vehicle. *Journal of Civil and Environmental Engineering Research*, Vol. 41, No. 3, pp. 317-325. (in Korean with English abstract)
- Lin, T. Y., Goyal, P., Girshick, R., He, K., and Dollár, P. (2017). Focal loss for dense object detection. *IEEE International Conference on Computer Vision(ICCV)*, 22-29 Oct, Venice, Italy, pp. 2980-2988.
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., and Johnson, B. A. (2019). Deep learning in remote sensing applications: a meta-analysis and review. *ISPRS journal of photogrammetry and remote sensing*, Vol. 152, pp. 166-177.
- McCulloch, W. S., and Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Vol. 5, No. 4, pp. 115-133.
- Miyato, T., Kataoka, T., Koyama, M., and Yoshida, Y. (2018). Spectral normalization for generative adversarial networks. *arXiv:1802.05957*.
- Mo, J.S., Seong, S.K., and Choi, J.W. (2021), Comparative evaluation of deep learning-based building extraction techniques using aerial images, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 39, No. 3, pp. 157-165. (in Korean with English abstract)
- Mohanty, S.P., Czakon, J., Kaczmarek, K.A., Pyskir, A., Tarasiewicz, P., Kunwar, S., Rohrbach, J., Janick, Luo,

- D., Prasad, M., and Fleer, S. (2020), Deep learning for understanding satellite imagery: an experimental survey, *Crowd AI*, <https://www.crowdai.org/challenges/mapping-challenge> (last date accessed: 13 November 2021).
- Moon, G.S., Kim, K.S., and Choung, Y.J. (2020), Land cover classification based on high resolution KOMPSAT-3 satellite imagery using deep neural network model, *Journal of the Korean Association of Geographic Information Studies*, Vol. 23, No. 3, pp. 252-262. (in Korean with English abstract)
- Paisitkriangkrai, S., Sherrah, J., Janney, P., and Van Den Hengel, A. (2016), Semantic labeling of aerial and satellite imagery, *ISPRS*, <https://www2.isprs.org/commissions/comm2/wg4/benchmark/semantic-labeling/> (last date accessed: 13 November 2021).
- Park, H. J. (2020), Trend analysis of korea papers in the fields of 'Artificial Intelligence', 'Machine Learning'and 'Deep Learning', *Journal of Korea Institute of Information, Electronics, and Communication Technology*, Vol. 13, No. 4, pp. 283-292. (in Korean with English abstract)
- Park, H.L., Byun, S.H., and Lee, H.S. (2020), Application of deep learning method for real-time traffic analysis using UAV, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 38, No. 4, pp. 353-361. (in Korean with English abstract)
- Park, J.M., Sim, W.D., and Lee, J.S. (2019), Automatic classification by land use category of national level LULUCF sector using deep learning model, *Korean Journal of Remote Sensing*, Vol. 35, No. 6-2, pp.1053-1065. (in Korean with English abstract)
- Park, M.G., Kwak, G.H., and Park, N.W. (2019), A convolutional neural network model with weighted combination of multi-scale spatial features for crop classification, *Korean Journal of Remote Sensing*, Vol. 35, No. 6-3, pp. 1273-1283. (in Korean with English abstract)
- Park, S. W. (2020). Detection of forest fire burned area using Landsat satellite images and Deep learning, Master's thesis, Pukyong National University, Busan, Korea, pp. 53.
- Park, S.C., Park, M.K., and Kang, M.G. (2003). Super-resolution image reconstruction: a technical overview. *IEEE signal processing magazine*, Vol. 20, No. 3, pp. 21-36.
- Park, S.M., Im, J.H., and S, H.S. (2001), Land cover classification of a wide area through multi-scene Landsat processing. *Korean Journal of Remote Sensing*, Vol. 17, No. 3, pp. 189-197. (in Korean with English abstract)
- Park, S.Y., Ahn, M.H., Lee, C.L., Kim, J.W., Jeon, H.G., and Kim, D.J. (2021), Evaluation of oil spill detection models by oil spill distribution characteristics and CNN architectures using Sentinel-1 SAR data, *Korean Journal of Remote Sensing*, Vol. 37, No. 5-3, pp. 1475-1490. (in Korean with English abstract)
- Park, S.Y., Yoon, S.H., and H, J. (2019), Image-based automatic detection of construction helmets using R-FCN and transfer learning, *Journal of Civil and Environmental Engineering Research*, Vol. 39, No.3, pp. 399-407. (In Korean with English abstract)
- Radford, A., Metz, L., and Chintala, S. (2015). Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv:1511.06434*.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2016). You only look once: unified, real-time object detection. *IEEE conference on computer vision and pattern recognition(CVPR)*, June. 26 – July. 1, Las Vegas, United States of America, pp. 779-788
- Rhee, S.Y., Jeon, W.S., and Choi, H. (2018), Analysis of deep learning applicability for KOMPSAT-3A satellite image classification, *Journal of the Korean Society for Geospatial Information Science*, Vol. 26, No. 4, pp. 69-76. (in Korean with English abstract)
- Ronneberger, O., Fischer, P., and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention*, 5-9 Oct, Munich, Germany, pp. 234-241.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A.C., and Fei-Fei, L. (2015), ImageNet Large Scale Visual Recognition Challenge, *IMAGENET*,<https://image-net.org/challenges/LSVRC/index.php> (last date accessed: 13 November 2021).
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. *2018 IEEE/CVF Conference on Computer*

- Vision and Pattern Recognition Workshops(CVPRW), 18-22 June, Salt Lake City, United States of America, pp. 4510-4520.
- Seong, S.K., Choi, S.K., and Choi, J.W. (2020), Cloud detection of planetscope imagery based on deeplab-v3+ by using transfer learning, *Journal of Korean Society for Geospatial Information Science*, Vol. 28, No. 4, pp. 25-32. (in Korean with English abstract)
- Seong, S.K., Mo, J.S., Na, S.I., and Choi, J.W. (2021), Attention gated FC-DenseNet for extracting crop cultivation area by multispectral satellite imagery, *Korean Journal of Remote Sensing*, Vol. 37, No. 5-1, pp. 1061-1070. (in Korean with English abstract)
- Shin, H.S., and Hong, S.C. (2018), A deep-learning based automatic detection of craters on lunar surface for lunar construction, *Journal of the Korean Society of Civil Engineers*, Vol. 38, No. 6, pp. 859-865. (in Korean with English abstract)
- Shin, Y.H., Hyung, S.W., and Lee, D.C. (2020), True orthoimage generation from LiDAR intensity using deep learning, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 38, No. 4, pp. 363-373. (in Korean with English abstract)
- Song, A.R., and Kim, Y.I. (2017), Deep learning-based hyperspectral image classification with application to environmental geographic information systems, *Korean Journal of Remote Sensing*, Vol. 33, No. 6-2, pp. 1061~1073. (in Korean with English abstract)
- Song, A.R., Choi, J.W., and Kim, Y.I. (2019), Change detection for high-resolution satellite images using transfer learning and deep learning network, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 37, No. 3, pp. 199-208. (in Korean with English abstract)
- Song, C.W., Wiratama Wahyu, Jung, J.H., Hong, S.J., Kim, D.H., and Kang, J.H. (2020), Urban change detection for high-resolution satellite images using U-Net based on SPADE, *Korean Journal of Remote Sensing*, Vol. 36, No. 6-2, pp. 1579-1590. (in Korean with English abstract)
- Song, H.H., Lee, H.C., Lee, S.J., Jeon, H.S., and Im, T.H. (2020), Design of video pre-processing algorithm for high-speed processing of maritime object detection system and deep learning based integrated system, *Journal of Internet Computing and Services*, Vol. 21, No. 4, pp. 117-126. (in Korean with English abstract)
- SpaceNet on Amazon Web Services (AWS). (2018), The SpaceNet Datasets, *SpaceNet*, <https://spacenet.ai/datasets/> (last date accessed: 13 November 2021).
- Wi, H.J., Maeng, J.G., Jang, I.S., and Hong, S.G. (2020), Aerial photography missing error detection and recovery using deep learning and reference images, *Journal of the Korean Society for Geospatial Information Science*, Vol. 28 No. 4, pp.33-40. (in Korean with English abstract)
- Won, T., Song, J., Lee, B., Pyeon, M. W., and Sa, J. (2020). Application of a deep learning method on aerial orthophotos to extract land categories. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 38, No. 5, pp. 443-453.
- Zhang, C., Wei, S., Ji, S., and Lu, M. (2019). Detecting large-scale urban land cover changes from very high resolution remote sensing images using CNN-based classification. *ISPRS International Journal of Geo-Information*, Vol. 8, No. 4, pp. 189.
- Zhao, J., Mathieu, M., and LeCun, Y. (2016). Energy-based generative adversarial network. *arXiv:1609.03126*.
- Zhao, Q., Sheng, T., Wang, Y., Tang, Z., Chen, Y., Cai, L., and Ling, H. (2019). M2det: a single-shot object detector based on multi-level feature pyramid network. *AAAI conference on artificial intelligence*, Jan. 27 – Feb. 1, Honolulu, Hawaii, United States of America, pp. 9259-9266.