

고해상도 위성영상과 인공지능을 활용한 국토 변화탐지 및 모니터링 연구: 실증대상 지역인 정읍시를 중심으로

A Study on the Land Change Detection and Monitoring Using High-Resolution Satellite Images and Artificial Intelligence: A Case Study of Jeongeup City

조나혜* · 이정주** · 김현덕***
Cho, Nahye · Lee, Jungjoo · Kim, Hyundeok

Abstract

In order to acquire a wide range of land that changes in real time and quickly and accurately grasp it, we plan to utilize the recently released high-resolution S.Korea's satellite image data and artificial intelligence (AI). Compared to existing satellite images, the spectral and periodic resolutions of S.Korea's satellite are higher, making them a more suitable data source for periodically monitoring changes in land. Therefore, this study aims to acquire S.Korea's satellite, select 8 types of objects to detect land changes, construct data sets for them, and apply AI models to analyze them. In order to confirm the optimal model and variable conditions for detecting 8 types of objects of various types, several experiments are performed and AI-based image analysis is technically reviewed.

Keywords: S.Korea's satellite, AI(artificial intelligence), Object detection, Land monitoring, Image analysis

1. 서론

본 연구는 실시간으로 변하는 국토의 다양한 정보를 광범위하게 취득하고, 이를 빠르고 정확하게 파악하기 위해 위성영상과 AI를 활용하고자 한다. 최근 국토위성 1호(2021년 3월~10월 촬영)의 영상이 공개됨에 따라 고해상도의 영상자료를 활용할 수 있게 되었

으며, 촬영 주기 역시 기존 위성영상이 6개월 이상의 주기를 가지는 데 반해 국토위성의 경우 동일지역 재촬영 주기가 4.6일로 크게 짧아져 국토를 모니터링하는 데 보다 적합한 자료원이 되었다.

위성영상을 분석하기 위한 여러 방법론들이 있지만, 국토의 다양한 변화를 보다 광역적 범위에서 빠르고 효율적으로 탐지하기 위해 본 연구는 AI 기술을 활

* 공간정보연구원 선임연구원 LX Spatial Information Research Institute (first author: nhcho@lx.or.kr)

** 경북대학교 과학기술실용화연구소 연구원 KNU Science and Technology Commercialization Research Center (corresponding author: jungju501@knu.ac.kr)

*** 공간정보연구원 선임연구원 LX Spatial Information Research Institute (hdlkim@lx.or.kr)

용하여 분석하고자 한다. 국토위성이 GSD(Ground Sample Distance) 50cm로 항공영상 25cm와 거의 유사하게 해상도가 좋아졌기 때문에 AI 기술을 활용하여 객체 탐지, 영역 분할 등 보다 효율적인 국토모니터링을 위한 다양한 연구가 시도될 수 있는 여건이 되었기 때문이다.

현재 국토위성을 활용한 선행연구로는 선박 및 물동량 모니터링에 활용하기 위해 YOLO모델을 사용하여 정박 중인 선박을 중심으로 화물선 및 소형 선박을 탐지 및 분류하는 연구가 확인된다(박상철 외 2022). 하지만, 광역적 범위의 국토모니터링을 위한 국토위성영상 데이터셋을 구축한 연구는 미비한 실정이다. 국토모니터링을 위해서는 특성이 다른 다양한 객체(건물, 비닐하우스, 농지, 임야, 하천, 벌목 등) 탐지 및 분석이 요구되는데, 기존 위성영상은 상대적으로 해상도 문제로 인해 특정 객체에 대한 데이터 셋 구축은 불가능에 가까웠다.

따라서 본 연구는 보다 넓은 차원에서 전 국토의 변화상을 탐지하고 미래를 예측하기 위해 과학적 분석 기법을 활용하고자 한다. 국토위성영상을 취득하고 AI를 활용하여 국토를 구성하는 주요 객체들을 탐지함으로써 국토 변화 정보를 데이터 기반의 국토모니터링을 하기 위한 영상분석 기술을 검토하고자 한다. 이를 위해 2장에서 기존 선행연구를 통해 국토변화를 탐지하기 위한 국내외 선행연구들을 분석하고, 영상 플랫폼별 다양한 국토정보를 분석하기 위한 방법론을 분석하고자 한다. 그다음 3장에서 국토변화 탐지를 위한 객체 유형을 선정하고, 영상자료 특성에 따른 전처리 프로세스를 제안하고자 한다. 전 국토 범위에서 위성영상을 구득하고 선정된 객체 유형을 탐지하기 위한 최적의 AI모델을 선정하고자 한다. 이를 위해 다양한 변수 조건에 따른 실험을 수행하고자 한다. 그리고 4장에서 최적의 모델을 선정하고 정확도 분석을 한 후, 실증대상 지역을 선정하여 현장검증을 통해 실제 모델추론을 통한 정확도와 비교분석 하고자 한다. 마

지막으로 전체 연구 결과 및 의의, 그리고 한계점을 논의하고자 한다.

2. 선행연구

위성영상 또는 항공영상을 활용하여 국토의 변화를 추적, 관찰하기 위한 많은 연구가 기존에 진행되어왔다. 원격탐사 기반의 국토모니터링 관련 선행연구는 토지피복 분류, 도시변화 탐지, 재난 모니터링, 주요 공간객체 변화 탐지 등으로 구분할 수 있다. 또한 4차 산업혁명 기술의 발달로 드론영상을 활용하여 소규모 지역에서의 변화탐지 및 분석에 대한 연구도 활발히 진행되고 있다.

위성영상 활용 선행연구로는 상대적으로 해상도는 낮지만, 주로 넓은 범위를 대상으로 토지피복분류, 시계열 분석 등을 통한 국토 변화를 광역적으로 분석하였다. 기존에 다양한 분광대를 활용한 분광 특성 분석 연구들이 주를 이루었으나, 최근 국토위성과 같은 고해상도의 영상이 보급되면서 AI 모델을 적용한 연구도 증가하고 있다. 토지피복분류를 위해 여러 AI 모델이 시도되고 있는데, 김준 외(2021) 연구는 다중시기 위성영상에 U-Net 모델을 활용하여 서울특별시 토지 피복 분류정확도를 개선하였고, 이성혁 외(2020) 연구는 Komsat-3 영상을 SegNet, U-Net, Deeplab V3+모델을 적용하여 토지피복 분류 각 항목별 최적의 알고리즘을 찾고자 하였다.

도시 변화를 분석하기 위해 분광 특성을 활용한 김지영 외(2019)는 Landsat 영상을 이용하여 대구 신서 혁신도시 개발 전·후 NDVI와 지표면 온도를 비교하였다. AI 모델을 활용한 송창우 외(2020)는 도시의 변화를 탐지하기 위해 KOMPSAT-3A 위성영상을 SPADE기반의 U-Net과 객체 영역기반 변화탐지 기법에 적용하였다. 도시를 구성하는 주요 공간 객체 중 하나인 건축물을 기준으로 두 시계열 영상의 객체별 변화량을 비교하여 영역 간의 변위 오차를 분석함으

로써 변화탐지를 수행하였다.

항공영상을 활용한 선행연구들은 국토지리정보원에서 무료로 제공받을 있다는 장점과 25cm 정도의 해상도를 바탕으로 시군구 단위의 중소규모 지역 범위에서 객체탐지 및 특성분석, 변화 모니터링 등으로 확인된다. 서기환 외(2018) 연구는 대전광역시를 대상으로 Deep U-Net 알고리즘을 활용하여 일반주택지 건물에 대한 분류정확도를 평가하였고, 오창석 외(2010) 연구는 개별공시지가 산정을 위한 토지특성조사에서 대부분 지가현황도면으로 필지가 조사되는 문제점을 해결하기 위해, 항공영상을 활용하여 정량적인 분석결과를 바탕으로 민원감소 및 예산절감과 같은 개선방안을 제시하였다. 최진호 외(2019)는 서울특별시 표준지를 대상으로 항공영상과 수치지형도를 활용하여, 토지특성조사에서 '고저' 항목에 대해 C4.5 모델을 적용함으로써 '고저' 항목에 대해 정량적인 분석방법을 제시하였다.

변화 모니터링관련 연구로 윤공현 외(2017)는 해빈 인근지역을 대상으로 시계열 항공영상을 이용하여 장기간의 해안선 변화 관측을 위한 방법을 제시하였으며, 해빈의 해안선 변화를 산정을 통하여 연안침식에 관한 정량적인 분석을 수행하였다. 이진학 외(2016)는 연안침식에서 태풍과 같은 침식의 주요원인이 발생한 후 수심측량 변화 모니터링을 수행하기 위해 항공영상을 활용하여 효과적이고 경제적인 수심측량 방법을 제안하였고, 이를 해수욕장 측량에 활용 및 평가하였다.

드론영상을 활용한 선행연구들의 경우 cm단위의 고해상도 영상을 활용, 데이터를 신속하게 취득할 수 있는 장점으로 인해 농업, 재난재해, 환경 등과 같은 다양한 분야에 AI를 활용하여 소규모지역에서 특정 객체에 대한 탐지 및 분석, 실시간 모니터링 등의 연구가 진행되고 있다. 농업분야에서 Moriya et al.(2017)은 초분광카메라로 얻은 영상 처리 및 분석 방법을 개발하여 모자이크 바이러스에 감염된 사탕수수를 식별

하고 인식하였으며, Honkavaara, E. et al.(2016)은 이탄 생성지역에서 초분광영상 기반 SWIR 대역과 VNIR 대역의 반사율 차이를 사용하여 토지표면 수분 탐지를 통해 생산 효율성과 환경 안전 측면을 향상하는 방법을 제안하였고, 류재현 외 (2022)는 노지작물에 대해 필지별 또는 작물 객체별로 모니터링하고 재배시기에 따른 영농단계별 정량적 의사결정 정보를 제공하기 위해 RGB영상과 NIR영상을 활용하여 생육 주기별 객체 탐지 및 정확도분석을 하였다.

재난재해분야에서 Lin, Z. et al.(2018)은 산불 감시 및 산불 진행상황 모니터링을 위해 Kalman filter기반의 방법론을 제안하였고, scalar field 모델을 개발하여 산불진행상황에 대해 평가하였다. Martínez-de Dios, et al.(2011)은 자동 산불 측정시스템 개발을 통해 드론과 지상 화재 전선의 위치와 모양, 화염 높이, 확산 속도 등을 실시간으로 탐지하여 GIS와 연계를 통해 화재의 잠재적 진화를 예측하고 소방자원의 최적 위치를 결정하는 연구를 진행하였고, Turner, D. et al.(2015)은 산사태 역학을 평가하기 위하여 시계열 드론영상을 활용, SfM기법을 적용하여 수평방향으로 4~5cm, 수직방향으로 3~4cm 정확도의 산사태 표면의 DSM을 생성하여 산사태 면적, 전단 경사 등의 변수를 측정하여 시간적 패턴을 분석하였다.

환경분야에서 Zhang, Y. et al.(2021)은 토양에서 아연 오염에 대한 분석을 위하여 머신러닝기법(SVM, GLM, RF 알고리즘)을 활용하여 위험 선별 및 등급 모델과 함량 추정 모델을 수립하였다. Youme, O. et al.(2021)은 세네갈의 세인트루이스 지역을 대상으로 드론영상과 CNN을 활용, CNN 모델에 이미지 분할 방법을 적용하여 불법투기 폐기물 자동감지 시스템을 개발하였다. Geraeds, M. et al.(2019)은 말레이시아 클랑 강에서 떠다니는 플라스틱 폐기물을 모니터링하기 위하여 고도별 드론영상을 통해 2.5cm이상의 플라스틱 폐기물을 탐지하였고, 최경아 외(2021)는 해양 쓰레기 모니터링의 현황을 점검, 개선하기 위하여 드

론영상에서 VGG Image Annotator를 사용하여 학습 데이터를 구축하고, VNet 모델을 활용하여 드론과 AI 탐지기술을 활용한 해양 쓰레기 관리체계를 제안하였다.

3. 실험

3.1. 국토변화 탐지를 위한 객체 유형 선정

국토를 모니터링하는 연구들은 크게 국토·토지관리 및 도시변화, 산림 및 녹지 훼손지 탐지 등으로 분류할 수 있으며, 전 국토의 변화를 영상자료를 활용하여 다양한 객체들을 탐지함으로써 직·간접적으로 분석하고 있다. 본 연구는 국토의 여러 변화상들을 파악하기 위해 위성, 항공, 드론 등 다양한 영상 플랫폼의 주기성, 실시간성, 고해상도 등을 특징을 적절히 활용하고자 한다.

국토위성의 해상도(50cm)를 고려했을 때, 상대적으로 고해상도의 항공영상(25cm) 및 저해상도의 위성영상(100cm)에서 탐지 가능한 수준을 포함할 수 있을 것이라 판단하였다. 국토의 변화를 파악하기 위한 선행연구와 국내외 AI 및 영상분야에서 구축하고 있는 객체 유형을 분석하였고, 실제 업무에서 많이 활용되고 있는 공부상 지목을 고려하여 후보군으로 선정하였다. 최종적으로 건물, 비닐하우스, 농지, 임야, 하천, 벌목, 태양전지판, 불법건축물 총 8종으로 선정하였으며, 이는 도시변화, 토지이용, 환경변화, 재난재해 등 다양한 분야에서 국토 변화 탐지 및 국토모니터링 연구에 활용될 수 있다.

3.2. 영상자료 전처리 프로세스 개발

본 연구는 국토위성을 기반으로 AI 학습 셋을 구축하고 최적의 모델이 선정되면, 이를 테스트베드에 적용해보고자 한다. 기본적으로 위성영상 데이터는 국

Table 1. Process of image data preprocessing

Process	SW	library	Image
Georeferencing	QGIS	georeferencer	satellite
Merge fan sharpening bands	GDAL	gdalbuildvrt	satellite
Deriving image statistics	GDAL	gdalinfo	satellite
Normalizing image	GDAL	gdal_translate	satellite
Tiling	GDAL	gdal_retile.py	satellite
Rasterization	GDAL	gdal_rasterize	satellite
Burn-in determination according to land_code	OGR	ogrinfo	labeling data
Merging	GDAL	gdal_calc.py	labeling data

토지리정보원에서 공개한 국토위성영상을 활용하였고, 국토정보플랫폼에서 총 19개 지역에 대한 영상 데이터를 획득하였다. 국토지리정보원의 국토정보플랫폼에서 제공하는 통합지도검색을 활용하였다.

국토정보플랫폼에서 다운받은 위성영상은 위치좌표가 포함되어 있지 않다. 연속수치지형도(건물)의 모서리 부분과 위성영상을 맞추어 tie-point를 지정하였다. 위성영상 1장당 최소 9개의 tie-point를 선정 후 지오레퍼런싱을 실시하였다. 변환 파라미터 중 변환 유형은 투영, 리샘플링 방법은 Nearest Neighbor를 사용하였다.

본 연구는 AI 분석을 위한 학습 데이터셋 구축에 두 가지 유형의 입력값 자료를 활용하였다. 먼저, 원시자료인 위성영상과 라벨링한 벡터자료이며, 이 자료들은 공간데이터로서 QGIS, GDAL, OGR 등의 다양한 공간정보 관련 오픈소스 라이브러리를 활용하여 처리할 수 있다. 위성영상과 라벨링된 자료를 딥러닝에서 활용 가능한 형태로 변환하기 위해 다음 Table 1과 같은 자료 가공 및 변환 프로세스를 개발하였다. 해당 프

로세스 중 일부 과정을 제외하고 Luigi 기반의 자동화 처리 체계를 도입하여 활용하였다.

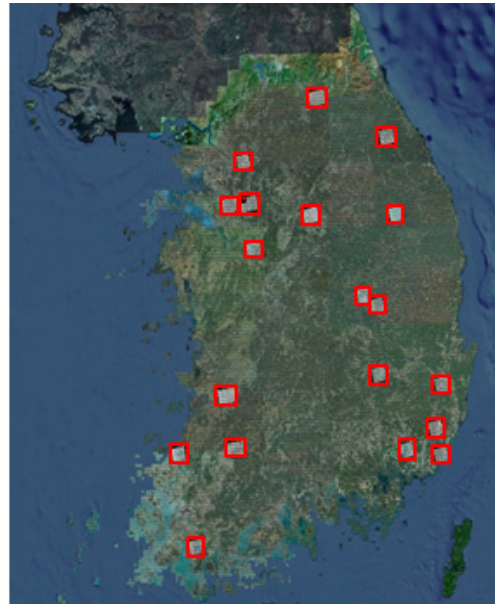
먼저, 원시 위성영상은 래스터 데이터로 국토지리 정보원에서 무상으로 서비스하고 있지만, 해상도 1m 이하의 경우 좌표정보를 제공하지 않기 때문에 지오 레퍼런싱을 통해 좌표값을 부여하는 과정이 필요하다. 그리고 팬 샤프닝 밴드병합을 통해 위성영상 컬러 해상도 1m를 팬크로매틱 흑백영상의 50cm로 해상도를 향상시켜서 활용하였다. 이렇게 원천자료로서의 위성영상은 영상 통계량 도출, 영상 정규화 과정을 거치게 되고, 특히 약 30000 * 30000 픽셀인 위성영상을 AI 모델에 입력하기에 적당한 크기인 512 * 512 픽셀로 타일링하는 작업이 수행되었다. 그 다음 의미없는 배경 타일 제거 순으로 프로세스를 진행하였다.

그 다음 벡터 형태의 라벨링 자료는 기구축 공간정보 즉, 연속수치지형도, 팜맵 등 오픈되어있는 데이터를 바탕으로 구축하고자 하는 객체에 대해 자동으로 라벨링되도록 하였으며, 이때 각 객체유형별 라벨링 레이어가 구축된다. 각각 라벨링된 데이터는 래스터로 변환 및 타일링하는 과정이 이루어지고, 객체 유형별 데이터를 하나로 병합하여 AI 모델 입력 값으로 활용된다.

3.3. 실험환경

본 연구의 위성영상 학습 데이터 셋 구축 범위는 총 19개 지역이며, 전국 광역시 및 도별로 고르게 분포하도록 선정하였다. 또한, 개발제한구역을 일부 포함할 수 있도록 수도권 및 광역시 인근 지역도 포함하도록 하였다.

19개에 대한 대상지역은 광역시(서울, 대구, 부산), 경기도(화성, 동탄), 충청도(천안, 청주), 강원도(영월, 춘천, 평창), 전라도(정읍, 영광, 담양, 해남), 경상도(의성, 양산, 김해, 상주, 경주)가 이에 해당한다(Figure 1). 오름 등 그 지역만의 지리적 특성이 있는 지역(예:




 Satellite imagery distribution map

Figure 1. Study area

제주도), 전체 위성 영상의 면적 중 바다가 차지하는 비율이 50%가 넘는 해안가 일부 지역은 본 연구에서 제외하였다.

검증 및 시험을 위한 지역은 도시 지역과 농촌 지역을 함께 선정하였다. 검증 지역으로는 농촌 지역인 담양, 도시 지역인 천안을 선정하였고, 시험 지역은 농촌 지역인 정읍, 도시 지역인 동탄을 선정하였다.

3.4. 학습 데이터 셋 구축

탐지할 객체는 3.1에서 선정한 바와 같이 총 8종으로 건물, 비닐하우스, 농지, 임야, 하천, 태양광, 벌목, 불법건축물이 해당한다. 19개의 실증 지역 중 15개의 지역은 총 6종의 객체(건물, 비닐하우스, 농지, 임야, 하천, 태양광)를 포함하며, 3개의 지역은 6종의 객체에 벌목을 추가하여 7개 객체를 포함하며, 1개의 지역은 7개 객체에 불법건축물을 추가한 8개의 객체를 포

함한다.

탐지 대상 객체를 추출하기 위해서는 전처리된 영상에서 벡터 형태로 객체의 영역과 위치를 표현하는 라벨링 데이터도 구축해야 한다. 라벨링 구축 계획은 1차와 2차로 나누어 수립하였다(Table 2). 1차 라벨링 대상 객체는 건물, 비닐하우스, 농지, 임야, 하천으로 연속수치지형도, 도로명주소, 팜맵 등 기구축되어 공개된 공간정보로부터 라벨링을 획득할 수 있다.

2차 라벨링 대상 객체는 태양광, 벌목, 불법건축물로 기구축된 공간정보에서 라벨링을 획득하기 어려워 수작업을 통해 구축할 수 있다. 1차 라벨링 구축 계획을 수행할 때는 원시영상 및 라벨링 자료 가공 및 변환 프로세스를 개발하는데 중점을 두었고, 2차 라벨링 구축 계획을 수행할 때는 수동 라벨링을 정교하게 수행하는 것을 목표로 하였다.

국토모니터링 대상 객체 8종 중 건물, 비닐하우스, 농지, 임야, 하천은 기존의 공간정보를 활용해서 자동으로 생성하기 때문에 많은 수량의 데이터 셋을 구축할 수 있다. 반면에 태양전지판, 벌목(훼손지), 불법건축물은 수동 라벨링으로 제작했기 때문에 데이터 셋의 양이 상대적으로 많이 적다. 따라서 객체 8종을 한 개의 데이터 셋으로 구성하여 모델을 학습시킬 경우,

클래스 불균형으로 인해 수동 제작된 3종의 객체에 대한 검출 정확도가 많이 저하된다. 이러한 경우 클래스 비율이 낮은 종류의 객체에 대해 데이터 증식을 수행하여 클래스 불균형을 완화시킬 수 있지만, 클래스 불균형이 너무 심할 경우에는 효과적이지 않다. 따라서 본 연구에서는 자동 생성된 5종의 객체와 수동 생성된 3종의 객체에 대한 각각의 데이터 셋을 이용하여 AI 모델을 학습시키고자 한다.

3.5. AI 모델 분석

본 연구는 건물과 비닐하우스와 같은 단일 객체 외에 농지, 임야, 벌목, 하천과 같은 영역 정보도 모두 포함되므로, Semantic Segmentation 기법의 적용이 적합하다고 판단하였으며, Semantic Segmentation의 대표적인 모델로 SegNet, PSPNet, DeepLab V3+, SETR 등이 있다. 또한, 최근에는 ViT(Vision Transformer)를 이용한 모델이 벤치마크에서 높은 성능을 나타내고 있다. 따라서 본 연구는 이미지 내에 있는 물체들을 의미 있는 단위로 분할하고 이미지의 각 픽셀이 어느 클래스에 속하는지 예측하기 위한 Semantic Segmentation 기법에 여러 유형의 CNN 모델들이 있지만 구조적으로 본다면 크게 3가지 정도 유형으로 나뉠 수 있다. 대표적으로 전통적인 FCN 방식을 사용하는 PSPNet, Semeantic Segmentation을 잘 해결하기 위한 방법으로 atrous convolution을 적극적으로 활용한 DeepLab V3+, 그리고 가장 최신 모델인 Swin Transformer까지 총 세 유형의 모델을 대표적으로 비교 분석하여, 국토모니터링 대상 객체 추출에 적합한 AI 모델을 선정하고자 하였다.

첫 번째 모델인 DeepLab V3+는 영상에서 특징을 추출하여 주어진 정보를 추상화하는 Encoder와 추상화된 정보에서 클래스 맵을 만들어내는 Decoder로 이루어져 있으며, Encoder에서는 backbone network가 영상 특징 추출을 담당한다. backbone network는

Table 2. Dataset composition

Types of data	Set of classes	Train (78%)	Valid ation (11%)	Test (11%)
Automatic 5 types	building, vinyl house, farmland, woodland, river	39,546	5,351	5,732
Manual 3 types	solar panel	7,377	922	923
	logging	660	83	82
	illegal building	540	68	67

Table 3. Comparative evaluation of AI model accuracy

No.	Train dataset	AI Model	mF1-score (without background)
1	Data set of this study	DeepLab V3+ ResNet101	71.17
2	(for detecting land change: automatic 5types)	PSPNet	65.33
3		Swin Transformer	32.88

Table 4. Comparative evaluation of AI model accuracy(Constructed dataset vs. Reference dataset)

No.	Train dataset	AI Model	mIoU(%)
1	Constructed dataset (for detecting land change: automatic 5types)	DeepLab V3+ ResNet101	58.64
2	reference dataset (LoveDA)		51.47

여러 가지 CNN 모델 가운데 하나를 선택할 수 있다.

두 번째 모델인 PSPNet은 기존 CNN 모델을 Semantic Segmantion에 더 적합하게 변형시킨 FCN(Fully-Convolutional Network)을 사용한다. 피라미드 형태의 풀링 모듈을 사용하여 지역뿐만 아니라 전역의 학습을 진행하여 학습 성능을 높였다.

세 번째 모델인 Swin Transformer는 Vision Transformer(ViT)기반의 모델이다. ViT는 기존의 CNN 모델보다 성능을 향상시킨 최신 모델이다. 그러나 ViT는 많은 데이터를 사전 학습해야 한다는 단점이 있다.

본 연구를 위한 국토변화 탐지를 위한 학습 데이터 셋에 대한 세 개 모델의 성능 비교 실험 결과, DeepLab V3+가 가장 높은 객체 검출 정확도를 보였다. Table 3은 각 모델의 객체 검출 정확도를 성능 측정 지표인 F1-score로 계산하여 보여준다. mF1-

score는 클래스별 F1-score를 모두 이용하여 계산된 산술 평균으로, 종합적인 성능 지표로 활용된다. AI 모델 비교 분석 결과 DeepLab V3+ 모델의 객체 검출 정확도가 71.17%로 가장 높게 나타났다.

Table 4는 국토변화 탐지를 위한 데이터 셋과 레퍼런스 데이터 셋을 비교하여 정확도를 분석하고자 하였다. 가장 성능이 좋았던 DeepLab V3+ 모델을 두 데이터 셋에 적용하였고, 객체 검출 정확도를 mIoU로 비교하였다. LoveDA (Remote Sensing Land-Cover Dataset for Domain Adaptive Semantic Segmentation)는 고해상도 위성영상 내 토지피복 정보의 분석을 위한 원격탐사 분야의 학습 데이터 셋이다.

레퍼런스 데이터셋 과의 검출 정확도를 비교했을 때 국토변화 탐지용 학습 데이터 셋을 활용했을 때 58.64%로 적정 수준인 것으로 확인됐다. 따라서 본 연구에서는 국토변화 탐지 대상 객체 검출 알고리즘을 DeepLab V3+ 모델로 선정하였고, 국토변화 탐지를 위한 데이터 셋 구축이 추가적으로 필요함을 확인하였다.

4. 실험결과

4.1. AI 모델 성능 지표 및 최종 모델 선정

본 연구에서 사용한 Semantic segmentation 모델의 정량 지표는 Accuracy, Precision, Recall, F1-score, IoU 등으로 확인 가능하다. Accuracy는 전체 데이터에 대해 예측값과 참값이 동일한 비율만을 의미하므로, 데이터의 클래스 구성이 불균형한 경우에는 성능 지표로 사용하는 것은 바람직하지 않을 수 있다. Accuracy를 보완하기 위한 정량 지표로는 Precision, Recall이 있다. Precision은 예측 중 실제 참값의 비율을 확인하며, Recall은 실제 참값 중 모델이 참으로 예측한 비율을 의미한다. Precision과 Recall은 한 지표가 높으면 다른 지표가 낮아지는 관계이다. 이를 보완

하기 위해 두 지표의 조화 평균인 F1-Score를 사용하면 Precision과 Recall 값이 적절히 반영된 성능 지표를 얻을 수 있다. IoU는 합집합과 교집합의 비율을 계산하기 때문에, 예측 면적이 실제 면적의 10%만 벗어나도, 그 이상의 값이 된다. 따라서 본 연구에서는 성능지표로 F1-Score를 활용했다.

$$F1 - score = 2 \times \frac{Recall \times Precision}{Recall + Precision}$$

Formula 1. F1-score

기구축된 공간정보(연속수치지형도)를 활용한 1차 라벨링으로 6개의 클래스(자동차 5종 및 배경 포함)로 구분된 학습 데이터를 생성하였고, 이를 기반으로 학습 및 추론을 진행하여 정확도 검증을 실시하였다. 모델은 DeepLab V3+를 사용하되, Backbone인 ResNet의 깊이를 각각 50, 101, 152개로 구분하여 세 가지 실험을 진행하였다(Table 5).

ResNet50을 사용한 경우, 배경을 제외한 Test mF1-Score는 48.70%였고, 클래스별 F1-Score의 경우 임야가 80.61%로 가장 높게 나타났다. 하천 클래스의 경우 3.13%가 학습이 제대로 되지 않았다.

ResNet101의 경우 배경을 제외한 Test mF1-Score는 71.17%로 Backbone의 깊이에 따라 학습이 더 잘 됨을 확인할 수 있었다. 가장 높은 F1-Score의 클래스는 농지로 87.10%로 사전-1 실험에 비해 6.50%p 상승하였다. 가장 낮은 F1-Score의 클래스는 건물로 51.86%이며, 19.79%p 상승하였다. 또한, ResNet50에서 학습이 거의 되지 않던 하천 클래스도 72.32%로 69.19%p가 상승된 것을 확인하였다.

ResNet152를 사용한 경우 배경을 제외한 Test mF1-Score는 38.55%로 ResNet101 보다 낮았다. 이를 통해 위성영상 데이터에 적합한 ResNet 모델의 최적의 깊이는 101임을 확인하였고, 사전 실험을 통해 DeepLab V3+와 ResNet101을 학습 모델로 선정

Table 5. Comparative evaluation about Backbone models of DeepLab V3+

AI Model	Backbone	mF1-score (%)	F1-score (%)	
DeepLab V3+	ResNet50	(without background)	background	72.17
		48.70	building	32.07
			vinyl house	47.08
			farmland	80.60
			woodland	80.61
	river	3.13		
	ResNet101	(without background)	background	77.86
		71.17	building	51.86
			vinyl house	58.05
			farmland	87.10
			woodland	86.49
	river	72.32		
	ResNet152	(without background)	background	68.45
		38.55	building	14.98
			vinyl house	24.80
farmland			66.56	
woodland			79.09	
river	7.33			

하였다.

4.2. 건물 객체 검출 성능 향상을 위한 실험

Table 6, Figure 2는 건물 객체 검출 성능을 높이기 위해 3가지 조건을 다르게 하여 총 8가지 실험을 수행한 결과이다. 첫 번째로 기존 1차 라벨링 대상을 모두 활용하지 않고, 건물 클래스만 단독으로 학습을 진행하였다. 두 번째로는 건물의 원천자료를 연속수치지형도가 아닌 도로명주소를 활용하여 학습을 진행하였

Table 6. Comparative analysis according to 3 conditions

No.	Set of classes	Pre-built spatial data	Data Augmentation	Test mF1-score (without background)
① Fig.a	background, building (2 objects)	Continuous digital topographic map	O	41.87
② Fig.b	background, building (2 objects)	Street name address	O	41.35
③ Fig.c	background, building (2 objects)	Continuous digital topographic map	X	14.39
④ Fig.d	background, building (2 objects)	Street name address	X	19.18
⑤ Fig.e	background, building etc. (6 objects)	Continuous digital topographic map	O	71.11
⑥ Fig.f	background, building etc. (6 objects)	Street name address	O	55.64
⑦ Fig.g	background, building etc. (6 objects)	Continuous digital topographic map	X	71.17
⑧ Fig.h	background, building etc. (6 objects)	Street name address	X	67.77

다. 마지막으로 데이터를 기존보다 4배 증식 후 학습을 진행하였다.

건물만 단독으로 학습하는 경우(①~④), Figure 2.a~d), 전체 클래스를 학습한 경우(⑤~⑧): Figure 2.e~h)보다 전체적으로 성능 지표가 낮게 나타났다. 특히, 데이터 증식을 하지 않은 경우(③④: 14.39%, 19.18%) 보다 데이터 증식을 수행한 경우(①②: 41.87%, 41.35%)가 상대적으로 성능 지표가 높게 나타났다. 건물 외 전체 클래스를 학습한 경우는 이와 반대로 데이터 증식을 수행한 경우(⑤⑥: 71.11%,

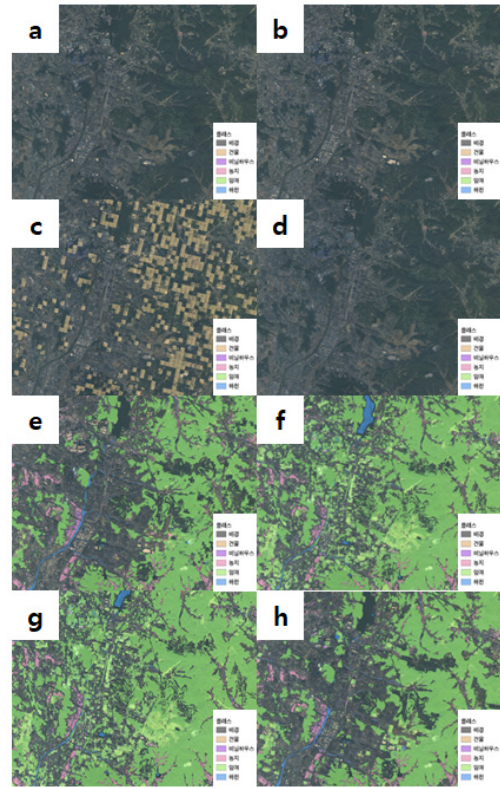


Figure 2. Results of inference by applying DeepLab V3+ and ResNet101 model to automatic labeling dataset (Building, vinyl house, farmland, woodland, river)

55.64%)가 수행하지 않은 경우(⑦⑧: 71.17%, 67.77%) 보다 성능 지표가 더 낮게 나타났다.

건물에 대한 원천 데이터를 연속수치지형도 또는 도로명주소를 활용한 경우 각각 성능 지표가 다르게 나타나는데, 건물만 단독으로 학습하고 데이터 증식을 하지 않은 경우(③④: 14.39%, 19.18%), 연속수치지형도(③: 14.39%) 보다는 도로명주소(④: 19.18%)를 활용한 경우가 성능 지표가 높았고, 그 외 나머지 경우(①②⑤~⑧)는 모두 연속수치지형도를 활용한 경우(①⑤⑦) 성능지표가 0.06~27.48% 정도 더 높게 나타났다.

마지막으로 데이터 증식을 수행하였을 때(①②⑤

⑥), 건물 단독 클래스를 학습한 경우(①②): 41.87%, 41.35%)는 성능이 향상되었지만, 전체 클래스 모두 학습한 경우는 데이터 증식을 하지 않았을 때(⑦⑧): 71.17%, 67.77%) 성능이 향상됨을 확인할 수 있다.

세 가지 조건을 종합하였을 때, 클래스 구성은 전체 클래스, 건물 원천자료는 연속수치지형도, 데이터 증식은 하지 않을 때 Test mF1-score가 71.17%로 가장 높은 성능을 보였고, 이 모델을 선정하여 활용하였다.

4.3. 수작업이 필요한 객체 라벨링 및 실험

기구축된 공간정보를 활용하기 어려워 수작업을 통해 구축된 2차 라벨링 대상 객체는 태양광, 벌목, 불법건축물이며, 이를 라벨링하고 모델을 분석한 결과는 다음과 같다(Table 7, Figure 3). 태양광 패널(①, a/a')과 벌목(②, b/b')에 대해 각각 수동 라벨링 구축 및 학습을 수행하였다. 태양광 패널의 테스트 데이터에 대해 추론을 진행한 결과는 Test mF1-Score 92.80%로 비교적 잘 탐지되었다. 벌목 지역의 테스트 데이터에 대해 추론한 결과 역시 Test mF1-Score 96.47%로 접면해 있는 도로를 제외하고 벌목 부근이 잘 탐지되었다. 불법건축물의 경우(③), 국토위성영상의 해상도로는 충분히 탐지가 어려웠기 때문에 건물 데이터에 속성 값으로 라벨링 하였다. 예를 들어, 화재에 취약한 샌드위치 패널의 경우 기존 건물과 유사하여 구별이 어렵고, 충분한 양의 학습데이터 확보가 어렵다. 속성 정보 형태로 학습데이터 구축하는 것에 의의가 있으며, 향후 드론 영상을 활용하여 불법건축물 탐지 시 추가 활용 가능하다.

4.4. 현장검증 및 분류정확도

본 연구는 AI 모델을 통해 정확도 검증을 수행하였고, 실제 현장에 적용하게 되었을 때의 정확도를 확인하기 위해 현장검증을 수행했다. 테스트 지역 중 하나




Figure 3. Results of inference by applying DeepLab V3+ and ResNet101 model to manual labeling dataset (a, a': solar panel, b, b': logging area)







Table 7. Comparison evaluation of models according to manual labeling dataset

No.	Set of classes	Pre-built spatial data	Data Augmentation	Test mF1-score (without background)
①	background, solar panel (2 objects)	manual labeling	○	92.80
②	background, logging area (2 objects)	manual labeling	○	96.47
③	background, illegal building (2 objects)	manual labeling	○	49.99

인 전북 정읍 지역을 대표적으로 현장검증을 수행하였다. 정읍 지역에 포함된 전체 객체에 대해 일부 표본을 뽑아 현장검증을 수행하고자 하였으며, 정읍 지역에 포함된 전체 객체 수는 54,000여 개이며, 이 중 각 객체 유형 8종별 랜덤 샘플링(증화추출) 방식을 통해 약 4,600여 개를 선정하였다.

건물 추론결과는 총 49건이며, 현장조사를 통해 41

Table 8. Comparative evaluation of AI detection and field verification

No.	AI analysis results	Field investigation results	Inconsistent content
①			All existing structures have been demolished
②			building is newly built
③			Areas inferred as farmland include vinyl houses

건이 일치하는 것으로 확인됐다. 나머지 8건의 객체 분류정보 불일치 내용은 Table 9와 같다. 불일치 8건 중 6건은 위성영상 내에 건물이 아닌 객체를 건물로 추론했는데, 이는 해당 객체의 크기가 작아서 위성영상의 공간해상도로 객체의 특징이 제대로 해석되지 않거나, 객체의 속성과 달리 외형적 특성이 건물에 가까웠기 때문인 것으로 판단된다. 특히 태양광패널의 경우, 영상의 번짐(blur) 현상으로 인해 육안으로도 식별이 어려웠다. 나머지 불일치 2건은 영상 촬영시점에는 객체가 존재했으나, 현재(2023년 1월)는 구조물이 모두 철거된 경우이다. 이는 추론결과가 잘못된 것이 아닌, 영상 촬영시점과 검증시점의 차이에 따른 것이다.

Table 8-①의 경우 영상 촬영시점에는 객체가 존재

했으나, 현재는 구조물이 모두 철거된 경우이다. 이는 추론결과가 잘못된 것이 아닌, 영상 촬영시점과 검증시점의 차이에 따른 것으로 판단된다. Table 8-②의 경우 영상 촬영시점에는 농지였으나, 현재 건물이 신축되었으며, Table 8-③은 농지에 인접한 투명비닐하우스가 농지 영역에 함께 포함되어 추론되었다.

현장검증을 통한 최종 분류정확도는 다음과 같다 (Table 9). 추론 결과 및 현장일치 건수를 중심으로 비교하였는데, 시점 차이로 인한 차이는 모델의 성능과 무관하다고 판단하여 집계에서 제외하였다. 최종 분류정확도는 임야, 농지, 건물, 비닐하우스 그리고 하천의 순으로 높게 나타났다.

Table 9. Classification accuracy of field verification

Object types	Inferred results (cases)	Results excluding time difference (cases)	Matching model and field results (cases)	Classification accuracy (%)
building	49	47	41	87%
vinyl house	8	6	5	83%
farmland	37	32	29	90%
woodland	1	1	1	100%
river	5	5	4	80%

5. 결론

본 연구는 국토위성 1호의 영상을 활용하여 AI 학습 데이터셋을 구축하고 모델을 분석하였다. 전국의 총 19개 지역의 위성영상을 모두 취득하였고, 위성영상을 활용한 전처리 프로세스를 정립하였다. 또한, AI 기반 국토 변화탐지 및 국토모니터링의 개념을 정립하고, 이를 위한 국토모니터링을 위한 객체탐지 대상을 분석하기 위해 총 8종의 객체(건물, 비닐하우스, 농지, 임야, 하천, 태양광패널, 벌목, 불법건축물)를 선정하였다. 또한, 각 객체별 512*512 픽셀 크기의 위성영상 56,000장 분량의 학습 데이터를 구축하였고, 객체 특성에 따라 기구축된 공간정보(연속수치지형도)를 활용하여 반자동 라벨링을 수행하였다.

먼저, 모델 성능 비교 실험 및 모델 backbone 선택 실험 결과 DeepLab V3+(ResNet101) 모델을 최종 선정하였다. 그리고 이때 객체의 특성이 다양하거나 무결성이 낮은 경우 정확도가 낮게 나오는 것을 확인하였고, 특히 정확도가 낮게 나오는 건물 클래스의 성능 향상을 위해 세 가지 변수를 도입하였다. 세 변수 중 원천 자료는 연속수치지형도, 데이터 증식 미실시, 건물 외 다른 클래스도 모두 학습하는 경우가 건물 클래스의 성능이 가장 높았고, 해당 실험에서 산출된 모델을 최

종 모델로 선정하였다.

본 연구에서 AI모델의 성능지표로는 F1-Score를 사용하였다. 자동으로 구축한 5종 객체의 평균 F1-Score(배경 제외)는 72.04%를 달성하였다. 수동으로 구축한 태양광 패널 및 벌목은 각각 92.80%, 96.47%의 F1-Score(배경 제외)를 달성하여 구축된 학습 데이터의 활용 정도가 높다고 볼 수 있다.

또한, 현장검증을 통해 모델에서 추론한 객체 유형과 실제 현장에서의 객체 또는 토지활용 형태를 조사하였다. 영상촬영 시점과 현장검증 시점의 차이로 인한 불일치 항목을 제외하고는 건물, 비닐하우스의 경우 영상의 해상도가 낮아 건물, 비닐하우스로 오분류되는 경우가 있었다. 농지의 경우, 계절적 특성으로 인해서 수목이 거의 없는 임야를 농지로 추론되기도 하였다. 그러나 영상에서는 비닐하우스, 농지 등으로 촬영되었지만, 현장조사 시점에 토지활용 형태가 달라지는 경우도 다수 발견되어 향후, 국토 변화를 정확하게 탐지하고 정보를 서비스하기 위해서는 시계열적인 분석이 필요함을 확인할 수 있었다. 또한, 불법건축물의 경우 국토 관리에 있어 가장 중요하게 분석되어야 할 대상이지만, 국토위성영상의 해상도로는 충분히 탐지가 어려워 정확한 데이터셋을 구축하지 못한 부분이 연구의 한계점으로 남는다.

본 연구는 국토 변화 탐지 및 국토 변화상에 대한 모니터링을 위한 기반 기술을 제시한 연구이며, 향후 개발제한구역, 국공유지 등 공부상 지목과 실제 토지이용현황의 차이를 다양한 유형의 영상과 AI 기술을 접목하여 보다 효율적으로 국토 변화 정보를 수집할 수 있음을 보여주었다. 이는 고해상도의 위성영상과 AI 기술을 활용하여 국토정보를 관리하는 프로세스의 개선을 가능하게 하였음을 의미한다. 국내외적으로 위성영상을 활용한 데이터셋 구축은 초기 단계이며, 현재 국토위성의 경우 위치정보가 민감 정보로 분류되어 접근 대상이 제한되어 있어 위치값 부여를 위해 위성영상에 대한 지오레퍼런싱을 수동으로 작업하였다.

이 때문에 기 구축된 원시자료들과 위성영상의 위치가 정확히 맞지 않아 성능지표가 떨어질 수밖에 없는 구조적인 한계점을 가진다. 향후 충분한 양의 다양한 데이터셋, 그리고 위치정보가 정확한 위성영상을 확보할 수 있다면, 행정 또는 공공 데이터와의 연계를 통해 보다 정확하고 유의한 국토변화에 대한 정보를 제공할 수 있을 것으로 사료된다.

참고문헌

References

- 김준, 송용호, 이우균. (2021). U-Net 기반 딥러닝 모델을 이용한 다중시기 계절학적 토지피복 분류 정확도 분석-서울지역을 중심으로. *대한원격탐사학회지*, 37(3), 409-418.
- Kim J, Song YH, Lee WK. (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*, 37(3), 409-418.
- 김지영, 김은정. (2019). 위성영상 분석과 현장조사를 통한 대구 신서혁신도시의 친환경적 도시계획의 적용 검토. *한국측량학회지*, 37(3), 143-156.
- Kim JY, Kim EJ. (2019). Application of Eco-friendly Planning of Sinseo Innovation City in Daegu using the Analysis of Satellite Image and Field Survey. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, 37(3), 143-156.
- 류재현, 한중곤, 안호용, 나상일, 이병모, 이경도. (2022). 드론 다중분광영상과 컴퓨터 비전 기술을 이용한 배추 객체 탐지 알고리즘 개발. *대한원격탐사학회지*, 38(5), 535-543.
- Ryu JH, Han JG, An HY, Na SI, Lee BM, Lee GD. (2022). Development of Chinese Cabbage Detection Algorithm Based on Drone Multi-spectral Image and Computer Vision Techniques. *Korean Journal of Remote Sensing*, 38(5), 535-543.
- 박상철, 박영빈, 장소영, 김태호. (2022). YOLO 알고리즘 기반 국토위성영상의 선박 모니터링 가능성 평가 연구: 부산 신항과 캘리포니아 오클랜드항을 대상으로. *대한원격탐사학회지*, 38(6), 1463-1478.
- Park SC, Park YB, Jang SY, Kim TH. (2022). A Study on Evaluating the Possibility of Monitoring Ships of CAS500-1 Images Based on YOLO Algorithm: A Case Study of a Busan New Port and an Oakland Port in California. *Korean Journal of Remote Sensing*, 38(6), 1463-1478.
- 서기환, 오창화, 김다윗, 이민영. (2018). 지속가능한 국토발전을 위한 토지이용변화 모니터링 방안 연구: 딥러닝 알고리즘 활용을 중심으로. 세종:국토연구원.
- 송창우, Wiratama Wahyu, 정지훈, 홍성재, 김대희, 강주형. (2020). SPADE 기반 U-Net을 이용한 고해상도 위성영상에서의 도시 변화탐지. *대한원격탐사학회지*, 36(6-2), 1579-1590.
- Song CW, Wahyu W, Jung JH, Hong SJ, Kim DH, Kang JH. (2020). Urban change detection for high-resolution satellite images using U-Net based on SPADE. *Korean Journal of Remote Sensing*, 36(6_2), 1579-1590.
- 신정일, 김익재, 황동현, 이종민, 임성하. (2017). 드론 영상을 이용한 소규모 가스 배출시설 탐지 가능성 분석. *지적과 국토정보*, 47(1), 213-223.
- Shin JI, Kim IJ, Hwang DH, Lee JM, Lim SH. (2017). Availability Analysis on Detection of Small Scale Gas Emission Facilities using Drone

- Imagery. *Journal of Cadastre & Land InformatiX*, 47(1), 213-223.
- 오창석, 임이택. (2010). 항공사진을 활용한 개별공시지가 조사의 개선방안에 관한 연구-광양시를 중심으로. *지적과 국토정보*, 40(1), 147-161.
- Oh CS, Lim IT. (2010). A Study on the Reform Measure of the Survey of Individual Public Land Price Using Aerial Photographs - Focused on the Gwangyang City -. *Journal of Cadastre & Land InformatiX*, 40(1), 147-161.
- 윤공현, 송영선. (2017). 디지털항공영상을 활용한 방아머리 해변의 해안선 변화 관측. *대한원격탐사학회지*, 33(6), 971-980.
- Yun KH, Song YS. (2017). Observation on the Shoreline Changes Using Digital Aerial Imagery for Bangamoeri Beaches. *Korean Journal of Remote Sensing*, 33(6), 971-980.
- 이성혁, 이명진. (2021). 항공 및 위성영상을 활용한 토지피복 관련 인공지능 학습 데이터 구축 및 알고리즘 적용 연구. *대한원격탐사학회지*, 37(5), 871-884.
- Lee SH, Lee MJ. (2021). A Study of Establishment and application Algorithm of Artificial Intelligence Training Data on Land use/cover Using Aerial Photograph and Satellite Images. *Journal of Remote Sensing*, 37(5), 871-884.
- 이진학, 신창주, 류경호, 정원무. (2016). 항공영상을 이용한 천해역에서의 수심 측량. *한국방재학회논문집*, 16(5), 351-358.
- Lee JH, Ryu KH, Shin CJ, Jung WM. (2016). Bathymetry estimation using aerial imagery for shallow water region. *Journal of The Korean Society of Hazard Mitigation*, 16(5), 351-358.
- 최경아. (2021). 드론 및 AI 를 이용한 해안 쓰레기 모니터링 체계: 제주도 사례 중심으로. *대한공간정보학회지*, 29(4), 127-138.
- Choi KA. (2021). A Coastal Garbage Monitoring System Using Drones and AI Technologies: Focusing on the Case of Jeju Province. *Journal of The Korean Society for Geospatial Information Science*, 29(4), 127-138.
- 최진호, 김준현. (2019). 토지특성 고저조사를 위한 공간정보 데이터 구축과 데이터 마이닝 분석. *한국측량학회지*, 37(6), 507-516.
- Choi JH, Kim JH. (2019). Spatial Information Data Construction and Data Mining Analysis for Topography Investigation of Land Characteristics. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, 37(6), 507-516.
- Geraeds, M., van Emmerik, T., de Vries, R., bin Ab Razak, M. S. (2019). Riverine plastic litter monitoring using unmanned aerial vehicles (UAVs). *Remote Sensing*, 11(17), 2045.
- Honkavaara, E., Eskelinen, M.A., Pölonen, I., Saari, H., Ojanen, H., Mannila, R., Holmlund, C., Hakala, T., Litkey, P., Rosnell, T., Viljanen, N., Pulkkanen, M. (2016). Remote Sensing of 3-D Geometry and Surface Moisture of a Peat Production Area Using Hyperspectral Frame Cameras in Visible to Short-Wave Infrared Spectral Ranges Onboard a Small Unmanned Airborne Vehicle (UAV). *IEEE Transactions on Geoscience and Remote Sensing*, 54(9), 5440-5454.
- Lin, Z., Liu, H. H., Wotton, M. (2018). Kalman filter-based large-scale wildfire monitoring with a system of UAVs. *IEEE Transactions on Industrial Electronics*, 66(1), 606-615.
- Martínez-de Dios, J. R., Merino, L., Caballero, F.,

- Ollero, A. (2011). Automatic forest-fire measuring using ground stations and unmanned aerial systems. *Sensors*, 11(6), 6328-6353.
- Moriya, E.A.S., Imai, N.N., Tommaselli, A.M.G., Miyoshi, G.T. (2017). Mapping Mosaic Virus in Sugarcane Based on Hyperspectral Images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(2), 740-748.
- Turner, D., Lucieer, A., De Jong, S. M. (2015). Time series analysis of landslide dynamics using an unmanned aerial vehicle (UAV). *Remote Sensing*, 7(2), 1736-1757.
- Youme, O., Bayet, T., Dembele, J. M., Cambier, C. (2021). Deep learning and remote sensing: detection of dumping waste using UAV. *Procedia Computer Science*, 185, 361-369.
- Zhang, Y., Xu, Y., Xiong, W., Qu, R., Ten, J., Lou, Q., Lv, N. (2021). Inversion study of heavy metals in soils of potentially polluted sites based on UAV hyperspectral data and machine learning algorithms. In 2021 11th Workshop on Hyperspectral Imaging and Signal Processing: Evolution in Remote Sensing, (1-5). IEEE.
- 국토지리정보원. 2023. 국토플랫폼 [인터넷]. [http://map.ngii.go.kr/ms/map/nlipCASImgMap.do]. 2023년 6월 4일 검색.
- (NGII) National Geographic Information Institute. 2023. National Land Platform [Internet]. [http://map.ngii.go.kr/ms/map/nlipCASImgMap.do]. Last accessed 4 June 2023.
-
- 2023년 05월 20일 원고접수(Received)
2023년 05월 22일 1차심사(1st Reviewed)
2023년 06월 07일 2차심사(2st Reviewed)
2023년 06월 21일 게재확정(Accepted)

초 록

실시간으로 변하는 국토를 광범위하게 취득하고, 이를 빠르고 정확하게 파악하기 위해 최근 공개된 고해상도 국토위성 영상자료와 인공지능(AI; Artificial Intelligence)을 활용하고자 한다. 기존 위성 영상에 비해 국토위성의 경우 분광 및 주기 해상도가 높아져, 국토의 변화상을 주기적으로 모니터링하는 데 보다 적합한 자료원이 되었다. 따라서 본 연구는 국토위성을 취득하여 국토 변화를 탐지하기 위한 객체 8종을 선정하고, 이에 대한 데이터 셋 구축 및 AI 모델을 적용하여 분석하고자 한다. 다양한 유형의 객체 8종을 탐지하기 위한 최적의 모델과 변수 조건들을 확인하기 위해 여러 실험을 수행하고, AI 기반의 영상분석을 기술적으로 검토해보고자 한다.

주요어 : 국토위성, 인공지능, 객체 탐지, 국토모니터링, 영상분석