

국토위성영상의 변화탐지를 위한 멀티 클래스 시멘틱 세그멘테이션 Multi-class Semantic Segmentation Using CAS500-1 Imagery for Change Detection

김용현¹⁾ · 박지상²⁾ · 윤대섭³⁾

Kim, Yonghyun · Park, Jisang · Yoon, Daesub

Abstract

Change detection using various satellite sensors has been considered a prominent field in remote sensing for several decades. Notably, the domain of building change detection has seen significant advancements with the application of various deep learning techniques in recent times. However, most studies in building change detection have focused on simple binary change detection(changes or non-changes), limiting the exploration of multi-class changes such as new construction or demolition of buildings. Moreover, the availability of the dataset for multi-class change detection has been constrained. To address these limitations, this study proposes a multi-class semantic segmentation methodology by adapting existing datasets to suit the characteristics of the CAS500-1. Specifically, aerial imagery datasets tailored to domestic regions are parsed and transformed to align with satellite imagery. Additionally, overseas datasets are augmented to overcome the limitations of side-looking observations in satellite imagery. Experimental results for multi-class change detection involving building construction and demolition indicate an IoU (Intersection over Union) of around 87% for the new construction label and approximately 58% for the demolition label. These results confirm the effectiveness of the proposed multi-class semantic segmentation approach. While certain instances of false positives occurred in regions with rapid changes in illumination, it is anticipated that such limitations can be overcome by augmenting the dataset with additional unchanged data in the future.

Keywords : Change Detection, Multi-class Semantic Segmentation, Data Transfer, CAS500, Compact Advanced Satellite 500, Benchmark Dataset

초 록

다양한 위성 센서를 활용한 변화탐지 연구는 지난 수십 년 동안 원격탐사 분야의 주요 연구 분야로 여겨져 왔으며, 특히 건물 변화탐지 분야는 최근 여러 딥러닝 기법이 적용되며 발전하고 있다. 하지만 건물 변화탐지의 대다수 연구가 단순한 변화 유무에 관한 연구로써 건물의 신축 또는 소멸 여부 등의 멀티 클래스 변화를 탐지하는 연구는 제한되며, 관련되어 공개된 데이터 또한 부족한 상황에 있다. 이와 같은 문제점을 해결하기 위해 본 연구에서는 공개된 기 구축 데이터 세트를 국토위성 1호에 적합하게 재구축하여 변화탐지에 적용하는 멀티 클래스 시멘틱 세그멘테이션 방법론을 제안한다. 세부적으로 국내 지역에 특화된 항공영상 데이터 세트를 위성 영상에 적합하게 파싱(parsing)하였고, 위성의 경사 관측(side-looking) 한계점을 극복하는 국외 데이터 세트를 동시에 증강(augmentation)하여 활용하였다. 건물의 신축 및 소멸을 나타내는 다중 클래스 변화탐지 실험에서 신축 레이블 IoU (Intersection Over Union)를 약 87%로 나타내었고, 소멸 레이블 IoU는 약 58%로 나타내 제안하는 방법론이 효과적임을 확인하였다. 추가적으로 조도의 변화가 급격하게 변화하는 데이터에서 일부 오탐지가 발생하였지만, 이는 변화가 발생하지 않은 추가 데이터를 향후 증강하여 극복될 수 있으리라 판단된다.

핵심어 : 변화탐지, 멀티 클래스 시멘틱 세그멘테이션, 데이터 이식, CAS500, Compact Advanced Satellite 500, 벤치마크 데이터 세트

Received 2023. 08. 23, Revised 2023. 08. 28, Accepted 2023. 08. 30

1) Corresponding Author, Member, Mobility UX Research Section, Electronics and Telecommunications Research Institute (E-mail: yhkeen@etri.re.kr)

2) Member, Mobility UX Research Section, Electronics and Telecommunications Research Institute (E-mail: parkji@etri.re.kr)

3) Mobility UX Research Section, Electronics and Telecommunications Research Institute (E-mail: eyetracker@etri.re.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

지구관측 위성 기술의 발전에 따라서 수십 센티미터의 매우 높은 공간 해상도를 갖는 광학, 열적외, 합성개구레이더 등의 다양한 위성들이 발사되어 원격탐사 분야에서 활용되고 있으며, 최근 인공지능 기반의 딥러닝 기법과 그래픽 처리 장치의 발전으로 그 활용 분야를 확대해 나가고 있다(Ma *et al.* 2019; Zhang *et al.* 2016). 국내의 경우 차세대 중형위성 플랫폼을 구축하고 있으며, 국토의 효율적인 모니터링 필요성에 따라서 2021년 국토위성 CAS(Compact Advanced Satellite)500-1호가 발사되어 운용되고 있다(Yoon *et al.* 2020). 국토위성 CAS500-1, -2호를 포함하는 차세대 중형위성 플랫폼에는 우주 핵심기술 검증용 CAS500-3호와 농업분야 활용을 위한 CAS500-4호, 수자원 분야 활용을 위한 CAS500-5호가 예정되어 있다. 국내도 위성정보를 이용하는 여러 활용 수요를 충족할 수 있는 기반을 구축하고 있으며, 국토위성의 경우 정밀 정사영상, 모자이크 영상 등 여러 산출물을 가공, 배포하며 사용자 친화형 제품으로 고도화되고 있다.

원격탐사 분야의 여러 활용 분야 중에서 변화탐지는 지상 객체의 상태, 현상을 관측하여 변화를 탐지하여 분석하는 분야로, 지난 수십 년 동안 공간정보 분야에서 주요 연구 분야로 인식되고 있다(Khelifi and Mignotte, 2020; Mo *et al.* 2021; Shi *et al.* 2020). 더욱이 최근 여러 딥러닝 기법을 이용한 변화탐지의 적용은 재난재해 모니터링, 토지피복도 제작, 도로 및 건물 추출 등의 분야에서 핵심 정보로 활용되고 있다(Afaq and Manocha, 2021; Zhu, 2017; Parelius, 2023). 이와 같은 다양한 활용 분야에 딥러닝 기법을 이용한 변화탐지를 적용하기 위해서는 관심 객체의 변화 여부가 레이블 처리된 데이터가 필수적으로 필요하다. 지도(supervised) 변화탐지의 경우 학습 과정에서 해당 레이블 데이터를 이용하여 학습을 수행하며, 비지도(unsupervised) 또는 반지도(semi-supervised) 변화탐지는 연구개발 측면에서 레이블된 데이터를 사용하지 않거나 적게 사용하게 된다(Bai *et al.* 2022). 하지만, 최종 개발이 완료된 변화탐지 파이프라인의 효용성을 평가하기 위해서는 레이블 데이터를 사용한 검증과정을 거쳐야 하므로 정교하게 구축된 학습데이터는 매우 중요하다 할 수 있다.

딥러닝 기반의 변화탐지 학습을 위하여 전 세계적으로 여러 학습 데이터 세트가 제안되어 활용되고 있다(Khelifi and Mignotte, 2020). 과거 소량의 저해상도 데이터를 이용한 변화탐지에서 최근 다량의 고해상도 학습데이터가 여러 연구에서 제안되었지만, 전 세계적으로 분포하며 개별 도시 구조물들의 3차원 형상이 반영된 데이터 세트는 아직 제한된 상황에 있다.

특히, 전 세계 도시의 건물 형상이 상이함을 고려하며 수 센티미터에서 수십 미터의 공간 해상도 범위를 갖는 대규모 학습 데이터 세트와 관련된 연구는 아직 미비한 현실에 있다. 즉, 위성영상을 이용한 변화탐지의 경우는 Shi *et al.*(2020)와 Shen *et al.*(2021)의 연구에서 언급되었듯이 1) 광범위한 촬영각 변화, 2) 급격한 조도의 변화, 3) 도시 형상의 복잡도를 고려하여야 함을 의미한다. 따라서, 변화탐지 파이프라인은 다양한 촬영각과 급격한 조도의 변화로 실제 변화가 발생하지 않았지만 변화된 객체 인스턴스로 인식되는 거짓양성(False Positive) 오류를 줄여야 하며, 학습데이터는 여러 도시 형상의 복잡도가 반영되어 있어야 함을 의미한다. 하지만, 앞서 언급한 것과 같이 공간적으로 전 지구로 널리 분포하며, 다양한 공간 해상도를 동시에 고려하는 학습데이터의 구축에는 많은 시간과 노동력이 발생하여 비용의 증가로 이어지게 된다. 더욱이, 이진(binary) 변화 여부 레이블 데이터 세트가 아니라 건물의 변화 여부 및 변화 형태를 나타내는 학습 데이터 세트를 이용한 연구는 극히 일부분에 그치는 현실에 있다(Zhu *et al.* 2022).

본 논문에서는 이와 같은 학습 데이터 세트 구축의 제약을 극복하기 위해서, 기 구축 학습데이터 세트를 국토위성 CAS500-1호에 적합하게 변형하여 활용하였고, 위성영상의 측면 관측(side-looking)에 강건한 변화탐지 결과를 획득하기 위해 국외의 측면 관측 변화탐지 학습데이터를 증강(augmentation)하였다(Shen *et al.* 2021). 더욱이 단순 이진 변화탐지가 아닌 건물의 신축 및 소멸을 나타내는 레이블 데이터를 이용한 멀티 클래스 시맨틱(semantic) 세그멘테이션(segmentation) 모델을 적용하여 그 가능성을 분석하였다. 실험 결과 m-IOU (mean-Intersection Over Union) 평가에서 약 60% 정확도를 나타내어 제안하는 방법론이 멀티 클래스 변화탐지에 효과적임을 확인하였다. 하지만 위성의 영상 획득 과정에서 발생하는 급격한 조도(illumination)의 변화가 있는 데이터에서는 일부 거짓양성 클래스 오탐지를 나타내었다. 본 논문의 구성은 다음과 같다. 2장에서는 기존에 구축된 국내의 변화탐지 학습 데이터 세트를 조사 및 분석하여 기술한다. 3장에서는 국토위성영상에 멀티 클래스(multi-class) 시맨틱 세그멘테이션 변화탐지를 적용하기 위해 학습데이터 세트를 생성하는 방법과 시맨틱 세그멘테이션 모델을 설명하며, 4장에서 실험 결과를 분석하여 제시하였다. 마지막으로 5장에서 제안하는 방법론을 토의하며 결론을 제시하였다.

2. 변화탐지 학습 데이터 세트


2.1 국내 데이터 세트

변화탐지와 관련된 국내 데이터 세트는 한국지능정보사회


진흥원이 운영하는 AI 통합 플랫폼 AI-Hub에서 2022년 공개한 항공영상 도시건물 변화탐지 데이터 세트가 있다. 학습데이터 구축의 주된 목적은 불법 건축물의 적발 과정이 단축될 수 있도록, 사람의 육안 판독 시스템을 인공지능 기반의 시스템으로 전환하는 데 있다. 데이터는 촬영한 항공영상 원천 데



(a) Building construction (red)



(b) Building extinction (green)



(c) Building renewal (blue)



(d) Building renewal (blue) and construction (red)

Fig. 1. Urban building change detection dataset of AI-Hub

이터와 원천 데이터의 속성을 표기한 *json* 파일 형식의 레이블링 데이터로 구성되어 있다. 항공영상 원천 데이터는 754×754 크기 화소 패치로 구성되며 전, 후 영상이 행(row) 방향 좌우로 연결되어 $754 \times 1,508$ 크기 화소로 구성되어 있다. 원천 데이터에 대한 변화유형, 갱신유형, 변화 영역 폴리곤을 포함한 레이블링 데이터를 파싱(parsing) 후에 Fig. 1과 같이 마스크 형태로 표현할 수 있다. 총 50,779장의 이미지를 레이블링 하였으며, 변화건물 인스턴스 객체는 101,874 객체로 원천 데이터 1장당 평균 2개의 변화건물 인스턴스 객체를 포함하였다. 하지만, 1장의 원천 데이터에 여러 변화건물 객체가 포함될 수 있으므로 공간적 면적 또는 화소 단위로 전체 변화 객체를 비율로 분석할 필요성이 존재한다.

건물의 변화유형은 새로운 건물의 생성을 의미하는 0: 신축, 기존 건물의 철거를 의미하는 1: 소멸, 건물 옥상의 신규 가설이나, 색상의 변화를 의미하는 2: 갱신으로 총 3가지 레이블로 구성되어 있으며 Fig. 1에 3가지 레이블을 포함하는 데이터를 나타내었다. 원천 데이터의 R-G-B 채널에서 변화 유형에 따라 변화된 건물을 추가적인 색상으로 나타내었다(신축: 붉은색, 소멸: 녹색, 갱신: 파란색). Fig. 1(a)는 신규 건물이 건축된 '신축' 변화 유형을 나타내며, Fig. 1(b)는 기존의 건물이 철거된 '소멸' 변화유형을 나타낸다. Fig. 1(c)는 건물의 옥상 구조물에 변화가 발생하였거나 색상이 변화된 '갱신' 변화 유형을 나타내고, Fig. 1(d)는 1장의 원천 데이터에 건물의 '갱신'과 '신축' 변화유형이 동시에 발생한 데이터를 나타내고 있다.

2.2 국외 데이터 세트

국외의 변화탐지 데이터 세트는 최근 Parelius (2023)의 연구와 Shi *et al.*(2020) 연구에 분석되어 정리되어 있다. 본 연구에서는 딥러닝 연구가 주로 시작된 2010년 이후부터의 데이터 세트를 조사하였으며, 데이터 공개 연도, 공간 해상도, 데이터 촬영 지역, 분광 밴드를 분석하여 Table 1과 같이 정리하였다. 국토위성 CAS500-1의 공간해상도와 유사한 0.5m 기준으로 조사하였으며 대표적인 데이터 세트인 LEVIR-CD 데이터와 3DCD (3D Change Detection) 데이터의 일부 학습데이터를 Fig. 2에 나타내었다(Chen and Shi, 2020; Coletta *et al.* 2022). LEVIR-CD 데이터 세트는 미국 텍사스 일대 7개 도시에서 20개 지역을 추출하여 두 시기 영상과 레이블 데이터를 생성하였지만, 도시의 밀도와 건물 형상이 국내 도시와 매우 상이함을 확인할 수 있다. 더욱이 데이터 세트 자체가 이진 변화만을 나타내고 있어 건물의 변화 여부만 탐지하고 변화 형태를 판단할 수 없게 되어 있다.

이와 유사하게 AICD (Aerial Imagery Change Detection) 데이터는 렌더링 엔진을 이용하여 가상의 이미지를 생성하였

고(Bourdis *et al.* 2011), WHU Building CD(Ji *et al.* 2018), DSIFN(Zhang *et al.* 2020), SYSU-CD(Shi *et al.* 2021), 3DCD(Coletta *et al.* 2022), Hi-UCD(Tian *et al.* 2022) 모두 공간적으로 특정한 지역에 한정되어 데이터가 구축되어 있다. 3DCD 데이터는 Figs. 2(d)-(g)에서 확인할 수 있듯이, 변화탐지를 위한 두 시기 영상과 변화된 건물 객체 레이블 및 변화된 객체의 수치표고모델(DSM: Digital Surface Model)을 동시에 제공하여 향후 3차원 변화탐지 연구에 효과적으로 활용될 수 있으리라 판단된다.

Table 1. Opened change detection datasets

Dataset (year)	Spatial resolution (m)	Location	Spectral bands
AICD (2011)	0.50	Synthetic	3
WHU Building CD (2018)	0.03 ~ 1.00	New Zealand	3
LEVIR-CD (2020)	0.50	Texas, USA	3
DSIFN (2020)	0.50	China	3
S2Lookings (2021)	0.50 ~ 0.80	Global	3
SYSU-CD (2021)	0.55	Hong Kong	3
3DCD (2022)	0.50	Spain	3
Hi-UCD (2022)	0.10	Estonia	3




Fig. 2. LEVIR-CD and 3DCD dataset

위성의 푸쉬 브room (push broom) 센서 또는 along-track 스캐너의 경우 스캐너 중심에서 멀어질수록 방사상의 왜곡(distortion)이 발생하고 이와 같은 왜곡은 변화탐지 연구에서 오탐지 원인을 증가시키는 요인으로 작용한다. 이와 같은 문제점을 극복하기 위해 최근 측면관측을 포함하는 위성영상을 이용하여 건물의 신축 및 소멸을 레이블링하여 제안된 S2Lookings (Satellite Side-Looking) 데이터 세트가 Fig. 3에 표기되어 있다(Shen *et al.* 2021). 국토위성과 유사한 공간 해상도를 가지며 미국, 중국, 북한을 포함하는 전 지구적 영역의 학습 데이터로 평균적으로 약 9.86°의 비연직 촬영각을 갖는다. S2Lookings 학습데이터 세트는 전체 5,000장의 영상과 레이블 데이터로 구성되며, 측면을 관측한 국토위성영상을 효과적으로 증강하는 데 활용할 수 있으리라 예상된다.

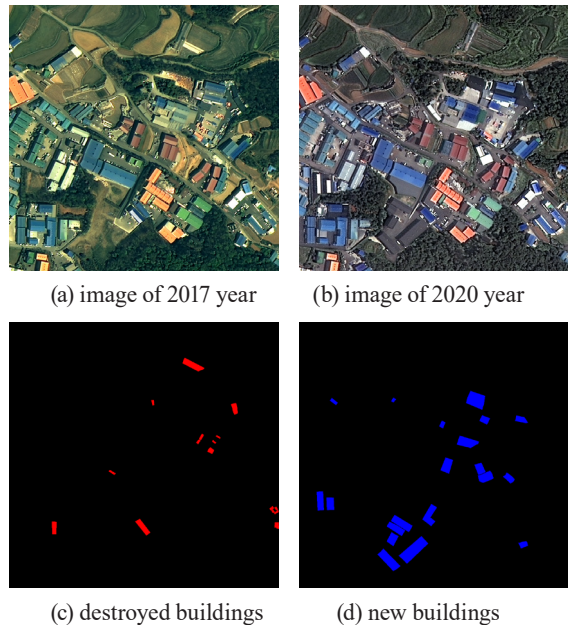


Fig. 3. S2Lookings dataset (a) 2017 data, (b) 2020 data, (c) destroyed buildings, and (d) new buildings

3. 멀티 클래스 시멘틱 세그멘테이션

본 3장에서는 국토위성을 위해 기존에 구축된 데이터 세트를 재구축하는 과정을 기술하며 변화탐지를 위한 멀티 클래스 시멘틱 세그멘테이션을 적용을 위해 이용한 딥러닝 학습 모델을 설명한다. 국토위성 1호는 국토의 효율적인 모니터링 및 공간정보 구축, 재난대응 등의 목적으로 2021년 3월 발사되었으며, 국토위성의 주요 상세 스펙은 Table 2와 같다.

Table 2. Specification of CAS500-1 (Yoon et al., 2019)

Specification	
Spectral resolution	Panchromatic: 0.5 m Multispectral: 2.0 m
Spectral range	Red: 450-520 nm Green: 520-600 nm Blue: 630-690 nm Near-infrared: 760-900 nm Panchromatic: 450-900 nm
Radiometric resolution	12 bits
Swath	≥ 12 km
Orbit	Circular sun-synchronous ascending orbit
Launch date	March 22, 2021

3.1 항공영상 데이터 재구축

국내 AI-Hub에 공개된 항공영상 도시건물 변화탐지 데이터 세트는 25cm 공간 해상도의 항공영상을 이용하여 건물의 변화유형을 크게 4가지(불변, 신축, 소멸, 갱신)로 구분하고 있다. 건물의 갱신유형으로는 층 변화, 철골 구조 완성, 설치·구조물 추가, 옥상 색상 변화, 외곽선 변화 종류로 총 5가지 유형을 구분하고 있다. 하지만, 25cm를 가지는 항공영상과 다르게 50cm 공간 해상도를 가지는 국토위성의 경우 철골 구조 완성, 설치·구조물 추가는 영상 판독으로도 구분하기 제한되며, 3차원 표고의 변화를 나타내는 층 변화인식은 한 장의 영상 데이터를 이용하게 되면 많은 제약사항이 따르게 된다. 따라서 본 연구에서는 건물의 변화유형을 크게 3가지(불변, 신축, 소멸)로 구분하였으며, 갱신 레이블의 경우 신축과 유사한 목적으로 수행한다는 가정에서 신축 레이블로 통합하였다. AI-Hub에 공개된 레이블 데이터는 json 파일 형식의 텍스트로 변화건물의 외곽을 포인트로 나타내 기록되어 있으며, 이를 파싱하여 폴리곤으로 변환하는 레이블링 과정을 수행하였다. 신축과 갱신을 나타내는 건물 변화의 경우 2 화소 값을 가지며 소멸된 건물의 경우 1 화소 값을 갖게 레이블 데이터를 구축하였다.

시멘틱 세그멘테이션에서 레이블을 균형되게 구축해 특정한 레이블에 딥러닝 모델이 편향된 결과를 나타내지 않는 것은 매우 중요하다. 국내 데이터의 경우 개별 레이블에 대한 통계치는 데이터와 함께 배포된 문서에 잘 기술되어 있으며, 본 연구에서는 50,779장의 모든 영상을 파싱하여 각각의 레이블이 점유하고 있는 화소 비율을 추가적으로 분석하였다. 데이터 세트 자체의 구축 규모 및 분포를 파악하기 위해서는 용도 지역별 구축 원천 데이터, 용도지역별 변화건물 객체의 비율

을 파악하는 것이 중요할 수 있지만, 컨볼루션(convolution)을 활용하는 딥러닝 네트워크 자체에서는 전체 영상에서 해당 변화 레이블 화소 비율 또한 매우 중요한 인자라 할 수 있다. Table 3에 AI-Hub 데이터 세트의 변화 화소 비율 통계를 나타내었다. 트레이닝 (training) 단계 데이터에서 신축 화소 비율은 3.5891%, 소멸 화소 비율은 0.2566%를 나타내 검증 (validation) 단계 데이터의 신축 화소 비율 3.5933%와, 소멸 화소 비율 0.2860%와 거의 유사함을 나타내 클래스 화소 비율 불균형 문제를 최초 데이터 구축 단계에서부터 고려하였음을 알 수 있다.

Table 3. Percentages of Changed Building Pixels – AI-Hub Dataset(%)

Change Labels	Steps	Validation	Training
	Constructed Buildings	3.5933	3.5891
Destroyed Buildings	0.2860	0.2566	
Changed Buildings	3.8793	3.8457	

3.2 S2Lookings 데이터 재구축


위성의 측면 관측을 고려하여 구축된 S2Lookings 데이터 세트는 5,000장의 1,024×1,024 크기 영상으로 구성되어 있으며, 국내 데이터 세트와 유사하게 건물의 신축 및 소멸 레이블로 구성되어 있다. 공간 해상도는 국토위성과 유사한 해상도를 갖지만, 국내 원천 데이터가 754×754 크기 영상으로 구성되어 있는 관계로 754×754 크기로 영상을 재배열(resampling) 하였다. 또한, 공개된 데이터 세트의 영상이 학습에 부적합하게 어두운 관계로 히스토그램의 상·하단을 2% 스트레칭하여 활용하였다 (Fig. 4). 추가적으로, 촬영된 시기로 구분되어 저장된 원천 데이터를 행 방향으로 통합하여 하나의 원천 데이터를 생성하였고, 신축 및 소멸 레이블 또한 국내 데이터와 동일하게 2 화소 값과 1 화소 값으로 재구축하였다.

국내 데이터와 동일하게 변화된 건물의 화소 점유 비율을 분석하여 Table 4에 나타내었다. 트레이닝 단계에서 신축 및 소멸 화소 비율은 각각 0.4436%와 0.2133%로 검증 단계의 화소비율 0.4471%와 0.2008%와 거의 유사함을 나타내고 있다. S2Lookings 데이터 세트 또한 최초의 데이터 구축 단계에서부터 레이블 불균형 및 화소 비율 불균형을 고려하였음을 파악할 수 있다. 다만 국내 데이터 세트는 변화된 건물 인스턴스 객체들을 반드시 포함하는 원천 데이터로 구축되어 트레이닝 단계에서 3.8457%와 검증 단계에서 3.8793% 화소 비율로 변화 화소를 포함한 반면에, S2Lookings 데이터 세트의 경

우 트레이닝 단계에서 0.6569% 화소 비율과 검증 단계에서 0.6479% 화소 비율로 점유율 나타내 약 6배 적은 변화지역을 포함하고 있음을 알 수 있다. 이와 같은 데이터 구축 통계치를 바탕으로 딥러닝 네트워크가 건물의 신축 레이블을 주된 관심 대상으로 학습하여 건물 소멸 레이블에서 낮은 정확도를 나타낼 가능성 존재한다.

Table 4. Percentages of Changed Building Pixels – S2Lookings Dataset(%)

Change Labels	Steps	Validation	Training
Constructed Buildings		0.4471	0.4436
Destroyed Buildings		0.2008	0.2133
Changed Buildings		0.6479	0.6569



(a) before histogram equalization

(b) after histogram equalization

Fig. 4. Histogram Equalization result (image ID of the dataset: 2937)



(a) data acquired on October 25, 2021

(b) data acquired on October 19, 2022

Fig. 5. CAS500-1 dataset for model inference

3.3 멀티 클래스 시멘틱 세그멘테이션 변화탐지

최근의 변화탐지 연구는 다중 토지피복 클래스들의 변화를 탐지하여 구분하는 다중 클래스 변화탐지 연구에 많은 관심이 집중되고 있으며, 더 나아가 변화의 시멘틱을 인식하

는 방향으로 고도화되고 있다(Zhu *et al.* 2022). 멀티 클래스 변화탐지는 전통적인 변화탐지에서 영상 분류 전-후를 비교하는 사후분류(post-classification) 변화탐지와 접근법은 유사하지만 변화된 객체 인스턴스의 외곽 경계 부분을 정확하게 추출해야 하므로 더 도전적인 분야라 할 수 있다. 본 연구에서 멀티 클래스 시멘틱 세그멘테이션을 위해 사용된 모델은 MA-Net(Multi-scale Attention Network)으로 인코더(encoder)는 timm-gernet을 이용하였으며 ImageNet에서 사전 학습된 네트워크를 전이받아 학습을 수행하였다(Fan *et al.* 2020). MA-Net은 의료용 스캔 영상에서 종양을 정확히 세그멘테이션 하기 위해 개발되었으며 멀티 스케일 네트워크 정보를 효과적으로 통합하기 위해 어텐션(attention) 메커니즘을 활용한다. MA-Net은 입력된 이미지를 다양한 크기 형태의 패치로 분할하여 로컬 및 글로벌 컨텍스트(context) 정보를 획득하고 통합적으로 정확한 세그멘테이션을 수행할 수 있지만 네트워크 구조가 복잡하여 연산에 일정한 시간 이상이 소요되는 단점이 있다. 학습과정에서 손실함수(loss)는 시멘틱 세그멘테이션에서 효과적으로 사용되는 식 (1)의 CCE(Cross Categorical Entropy) 손실함수를 사용하였다(Yeung *et al.* 2022).

$$CCE(y, p) = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \cdot \log(p_{i,c}) \quad (1)$$

여기서, $y_{i,c}$ 는 레이블 데이터의 one-hot 인코딩 스키마이며, $p_{i,c}$ 는 각각 클래스의 예측된 행렬을 의미한다. 첨자 c 와 i 는 변화 클래스 레이블과 화소를 나타낸다. 또한, 평가 지표로는 시멘틱 세그멘테이션 분야에서 많이 활용되는 IoU(Intersection over Union)를 이용하였다.

4. 실험 결과 및 분석

본 연구에서는 건물의 변화 형태를 3가지 멀티 클래스(불변, 신축, 소멸)로 시멘틱 세그멘테이션하는 연구를 수행하였으며, 앞서 기술한 국내 50,779장의 데이터와 국외 S2Lookings 5,000장을 통합하여 총 55,779장을 이용하였다. 연구의 재현성(reproducibility)을 위해 seed를 사용하였으며 전체 데이터의 20%를 검증용 데이터 세트로 이용하였다. 딥러닝 학습을 위해 사용된 연산 서버의 경우 인텔 Xeon(R) W-2235 3.80GHz, RAM 256GB 하드웨어로 구성되어 있으며 그래픽카드의 경우 두 개의 NVIDIA의 48GB RTX A6000을 NVLink로 상호 연결하여 총 96GB의 그래픽카드 메모리로 학습을 수행하였다. batch 크기는 8을 이용하였고 총 30

번의 epochs 실험에서 연속된 epoch에서 더 이상 손실함수가 더 이상 감소하지 않을 경우 학습을 조기 종료하는 epoch 옵션을 10으로 세팅하여 학습하였다. Optimizer는 AdamW를 활용하였고 learning rate는 $1e-3$ 으로 설정하였다. 전체 30번의 epochs에서 조기 종료 옵션에 따라서 최종 28 epochs까지 학습이 진행되었다. 학습이 완료된 후 시각적 평가를 위해 추론(inference)에 이용된 서울지역 국토위성은 그림 Fig. 5에 나타나어져 있으며 국토지리정보원으로부터 제공받았다. Fig. 5(a) 시기-1 영상은 2021년 10월 25일 촬영되었으며 Fig. 5(b) 시기-2 영상은 2022년 10월 19일 촬영으로 거의 정확하게 12개월의 시간 차이를 나타내고 있다. 해당 시기는 창경궁 및 세운상가 일대의 공사로 건물들의 철거와 신축이 발생한 시기로 본 연구의 목적에 부합하는 유효한 지역으로 연구지역을 선정하였다.

정량적 평가지표로 이용한 IoU는 기하학적 측면에서 변화로 인식된 객체 인스턴스의 연관성을 평가하기 위해 사용된다. 즉, 속성적으로 동일한 인스턴스일 때 중첩된 영역의 비율로 정의된다. 다시 말해 변화된 객체의 경계를 정확하게 탐지하고 변화의 종류를 나타내는 멀티 클래스를 동일하게 인식하였을 때 높은 값을 나타내게 된다. 실험 결과 건물 신축의 경우 손실함수의 값이 빠르게 감소하여 최종 IoU는 0.8734를 나타내었고, 건물 소멸의 경우 손실함수의 값이 느리게 감소하여 최종 IoU는 0.5868을 나타내었다(Table 5). 건물 신축의 정확도에 비해 건물 소멸의 정확도가 낮은 이유는 최종 학습데이터 분석에서 기술하였듯이 변화 레이블 비율이 건물 소멸에 비해 건물 신축이 높아서라 예상되지만, 향후 추가적인 분석이 필요할 것으로 판단된다. 또한, 본 연구에서는 신축과 소멸에 대한 손실함수의 가중치를 동일하게 1:1로 부여하였지만, 향후 부족한 변화 레이블 비율을 역수로 환산하여 손실함수를 가중하는 개별화(customization)된 손실함수를 이용하여 딥러닝 네트워크를 훈련하는 방법을 고려해 볼 수 있다.

시각적 분석을 위해 변화 레이블을 올바르게 탐지한 데이터를 Fig. 6에 나타내었다. 항공영상 Fig. 6(a)는 건물이 소멸된 위치를 녹색 레이블로 표기하고 있으며, Fig. 6(b)는 국토위성에서 관측한 건물 옥상의 구조물 변화를 붉은색으로 표기하고 있다. Fig. 7은 시각적 평가를 위해 국토위성영상을 이용한 학습 모델 추론 결과이며 두 데이터 모두 거짓양성 오류를 나타내고 있다. Fig. 7(a)는 급격하게 변화하는 조도의 영향으로 건물의 옥상에 변화가 없지만 신축 레이블로 탐지한 영역이며, Fig. 7(b)는 국토위성의 촬영각이 상이하여 발생하는 그림자의 위치 차이로 변화가 발생하지 않은 건물을 변화된 객체

Table 5. Quantitative result of IoU

Change Labels	IoU
Building construction	0.8734
Building demolition	0.5868



(a) Building extinction




(b) Building construction

Fig. 6. Correctly recognized changes (a) AI-Hub data and (b) CAS500-1 data



(a) rapid illumination changes



(b) shadow changes

Fig. 7. False positive errors (a) illumination changes and (b) shadow effects

인스턴스로 탐지하였다. 경사 관측 데이터를 다량 보유한 국외 데이터를 이용하여 학습데이터 세트를 증강하였지만, 그림자 영향 등 추가적으로 고려할 부분을 확인할 수 있었다. 하지만, 이와 같은 거짓양성 오류는 상이한 그림자가 존재하지만, 변화가 발생하지 않았거나 조도가 급격하게 변화하였지만, 변화가 발생하지 않은 추가 학습데이터를 증강하여 극복될 수 있으리라 예상된다.

5. 요약 및 결론

본 연구에서는 국토위성영상을 이용한 멀티 클래스 변화 탐지를 위해 국내외 기 구축된 데이터 세트를 국토위성영상에 적합하게 재구축하여 시멘틱 세그멘테이션을 적용하는 방법론을 제안하였다. 국내 도시의 형상을 반영하는 항공영상 도시건물 변화탐지 데이터 세트를 이용하여 재구축 적용하였고, 이 과정에서 변화의 다양한 형태를 나타내는 레이블을 축약하여 활용하였다. 또한, 측면을 관측할 수 있는 위성영상의 자연스러운 특징을 극복하기 위해 측면 관측 영상을 다량 포함하는 국외 변화탐지 데이터 세트를 활용하여 학습데이터를 증강하여 활용하였다. 이와 같은 연구는 변화를 인식하고자 하는 관심 지역과 유사한 도시 형태를 레이블링한 정사(ortho) 영상 데이터가 존재하지만, 공간 해상도가 위성영상과 상이할 경우 효과적으로 적용할 수 있을 것으로 판단된다. 실제 재구축된 데이터 세트를 이용한 결과 신축 IoU는 약 87%, 소멸 IoU는 약 59%를 나타내어 정량적으로 그 효과성을 입증하였지만, 시각적 평가를 위한 국토위성영상을 이용한 추론 결과 조도가 급격하게 변화하는 지역에서는 오탐지를 나타내어 추가적인 연구의 필요성을 확인하였다. 하지만 이와 같은 오탐지는 조도가 급격하게 변화하지만, 실제 건물들의 변화가 없는 지역을 다량으로 증강하여 극복할 수 있으리라 판단된다. 향후, 국외의 3차원 변화탐지 데이터를 국내에 적용적으로 활용하는 방법과 2차원 및 3차원 데이터가 교차로 존재하는 경우를 가정하여 변화탐지 연구를 고도화하며 수행할 예정이다.

감사의 글

본 연구는 국토교통부/국토교통과학기술진흥원의 디지털 국토정보 기술개발사업의 지원으로 수행되었음 (과제번호: RS-2022-00142501).

References

- Afaq, Y. and Manocha, A. (2021), Analysis on change detection techniques for remote sensing applications: A review, *Ecological Informatics*, Vol. 63, p. 101310. <https://doi.org/10.1016/j.ecoinf.2021.101310>
- Bai, T., Wang, L., Yin, D., Sun, K., Chen, Y., Li, W., and Li, D. (2022), Deep learning for change detection in remote sensing: a review, *Geo-spatial Information Science*, pp. 1-27. <https://doi.org/10.1080/10095020.2022.2085633>
- Bourdis, N., Marraud, D., and Sahbi, H. (2011), Constrained optical flow for aerial image change detection, *In 2011 IEEE International Geoscience and Remote Sensing Symposium*, pp. 4176-4179. <https://doi.org/10.1109/IGARSS.2011.6050150>
- Chen, H., and Shi, Z. (2020), A spatial-temporal attention-based method and a new dataset for remote sensing image change detection, *Remote Sensing*, Vol. 12, No. 10, p. 1662. <https://doi.org/10.3390/rs12101662>
- Coletta, V., Marscci, V., and Ravanelli, R. (2022), 3DCD: A new dataset for 2D and 3D change detection using deep learning techniques, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. 43, pp. 1349-1354. <https://doi.org/10.5194/isprs-archives-XLIII-B3-2022-1349-2022>
- Fan, T., Wang, G., Li, Y., and Wang, H. (2020), Ma-net: A multi-scale attention network for liver and tumor segmentation, *IEEE Access*, Vol. 8, pp. 179656-179665. <https://doi.org/10.1109/ACCESS.2020.3025372>
- Ji, S., Wei, S., and Lu, M. (2018), Fully convolutional networks for multisource building extraction from an open aerial and satellite imagery data set, *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 57, No. 1, pp. 574-586. <https://doi.org/10.1109/TGRS.2018.2858817>
- Khelifi, L. and Mignotte, M. (2020), Deep learning for change detection in remote sensing images: Comprehensive review and meta-analysis, *IEEE Access*, Vol. 8, pp. 126385-126400. <https://doi.org/10.1109/ACCESS.2020.3008036>

- 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.
<https://doi.org/10.1016/j.isprsjprs.2019.04.015>
- Mo, J., Seong, S., and Choi, J. (2021), Change detection of building objects in urban area by using transfer learning, *Korean Journal of Remote Sensing*, Vol. 37, No. 6-1, pp. 1685-1695.
<https://doi.org/10.7780/kjrs.2021.37.6.1.16>
- Parelius, E. J. (2023), A Review of Deep-Learning Methods for Change Detection in Multispectral Remote Sensing Images, *Remote Sensing*, Vol. 15, No. 8, pp. 2092.
<https://doi.org/10.3390/rs15082092>
- Shen, L., Lu, Y., Chen, H., Wei, H., Xie, D., Yue, J., Chen, J., Lv, S., and Jiang, B. (2021), S2Looking: A satellite side-looking dataset for building change detection, *Remote Sensing*, Vol. 13 No. 24, pp. 5094.
<https://doi.org/10.3390/rs13245094>
- Shi, Q., Liu, M., Li, S., Liu, X., Wang, F., and Zhang, L. (2021), A deeply supervised attention metric-based network and an open aerial image dataset for remote sensing change detection. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 60, pp. 1-16.
<https://doi.org/10.1109/TGRS.2021.3085870>
- Shi, W., Zhang, M., Zhang, R., Chen, S., and Zhan, Z. (2020), Change detection based on artificial intelligence: State-of-the-art and challenges. *Remote Sensing*, Vol. 12, No. 10, p. 1688.
<https://doi.org/10.3390/rs12101688>
- Tian, S., Zhong, Y., Zheng, Z., Ma, A., Tan, X., and Zhang, L. (2022), Large-scale deep learning based binary and semantic change detection in ultra high resolution remote sensing imagery: From benchmark datasets to urban application. *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 193, pp. 164-186.
<https://doi.org/10.1016/j.isprsjprs.2022.08.012>
- Yeung, M., Sala, E., Schönlieb, C.B., and Rundo, L. (2022), Unified focal loss: Generalising dice and cross entropy-based losses to handle class imbalanced medical image segmentation. *Computerized Medical Imaging and Graphics*, Vol. 95, p. 102026.
<https://doi.org/10.1016/j.compmedimag.2021.102026>
- Yoon, S.J., Son, J., Park, H., Seo, J., Lee, Y., Ban, S., et al. (2020), CAS 500-1/2 image utilization technology and system development: achievement and contribution, *Korean Journal of Remote Sensing*, Vol. 36, No.5-2, pp. 867-879.
<https://doi.org/10.7780/kjrs.2020.36.5.2.2>
- Zhang, C., Yue, P., Tapete, D., Jiang, L., Shangguan, B., Huang, L., and Liu, G. (2020), A deeply supervised image fusion network for change detection in high resolution bi-temporal remote sensing images, *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 166, pp. 183-200.
<https://doi.org/10.1016/j.isprsjprs.2020.06.003>
- Zhang, L., Zhang, L., and Du, B. (2016), Deep learning for remote sensing data: A technical tutorial on the state of the art, *IEEE Geoscience and Remote Sensing Magazine*, Vol. 4, No. 2, pp. 22-40.
<https://doi.org/10.1109/MGRS.2016.2540798>
- Zhu, Q., Guo, X., Li, Z., and Li, D. (2022), A review of multi-class change detection for satellite remote sensing imagery, *Geo-spatial Information Science*, pp. 1-15.
<https://doi.org/10.1080/10095020.2022.2128902>
- Zhu, Z. (2017), Change detection using landsat time series: A review of frequencies, preprocessing, algorithms, and applications. *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 130, pp. 370-384.
<https://doi.org/10.1016/j.isprsjprs.2017.06.013>