

# 국토위성영상 기반 건물 변화 탐지 GeoAI 학습용 데이터셋

진동혁<sup>1</sup> , 박지상<sup>2</sup> , 장유나<sup>3</sup> , 이승하<sup>3</sup> , 지준화<sup>4,\*</sup> 

<sup>1</sup>석사과정생, 국립부경대학교 데이터공학과, 부산광역시 남구 용소로 45, 48513, 대한민국

<sup>2</sup>책임연구원, 한국전자통신연구원 모빌리티항법연구실, 대전광역시 유성구 가정로 218, 34129, 대한민국

<sup>3</sup>학부과정생, 국립부경대학교 데이터정보과학부 빅데이터융합전공, 부산광역시 남구 용소로 45, 48513, 대한민국

<sup>4</sup>조교수, 국립부경대학교 데이터정보과학부 빅데이터융합전공, 부산광역시 남구 용소로 45, 48513, 대한민국

## GeoAI Dataset for Building Change Detection from CAS500-1

DongHyuk Jin<sup>1</sup>, Ji Sang Park<sup>2</sup>, Yuna Jang<sup>3</sup>, Seungha Lee<sup>3</sup>, and Junhwa Chi<sup>4,\*</sup>

<sup>1</sup>Master Student, Department of Data Engineering, Pukyong National University, 45 Yongso-ro, Nam-gu, 48513 Busan, South Korea

<sup>2</sup>Principal Researcher, Mobility and Navigation Research Section, Electronics and Telecommunications Research Institute, 218 Gajeong-ro, Yuseong-gu, 34129 Daejeon, South Korea

<sup>3</sup>Undergraduate Student, Major in Big Data Convergence, Division of Data and Information Sciences, Pukyong National University, 45 Yongso-ro, Nam-gu, 48513 Busan, South Korea

<sup>4</sup>Assistant Professor, Major in Big Data Convergence, Division of Data and Information Sciences, Pukyong National University, 45 Yongso-ro, Nam-gu, 48513 Busan, South Korea

Received May 7, 2025

Revised June 20, 2025

Accepted June 30, 2025

### Corresponding Author

Junhwa Chi

Tel: +82-51-629-4615

E-mail: [jchi@pknu.ac.kr](mailto:jchi@pknu.ac.kr)

Building change detection (BCD) is essential for urban planning, disaster response, and environmental monitoring. Existing datasets, such as WHU-CD, LEVIR-CD, and SYSU-CD, as well as overseas satellite imagery datasets, have limitations in reflecting South Korea's distinctive high-density urban morphology. Domestic aerial datasets, including AI-based national park change monitoring and urban BCD datasets, also suffer from varying sensor resolutions and limited applicability to satellite-based monitoring. To overcome these challenges, we introduce a high-resolution BCD dataset based on Compact Advanced Satellite 500-1 (CAS500-1), launched in 2021. This dataset utilized 0.5 m/pixel satellite imagery collected from 2021 to 2024 across diverse regions, including Seoul, Busan, and Daejeon. The dataset construction involved precise image alignment, RGB band synthesis, histogram stretching for contrast enhancement, and polygon-based labeling to identify urban changes. Additionally, format conversions were applied to ensure deep learning compatibility, generating 3,803 paired image patches (256×256 pixels). To validate the dataset, we employed ChangeMamba, a model integrating a visual state space model for spatiotemporal change detection. The model trained on our dataset achieved an F1 score of 0.79 and an intersection over union (IoU) of 0.66, outperforming models trained on different BCD datasets in cross-dataset tests, where the latter scored significantly lower (e.g., F1, 0.18 and IoU, 0.10 for the model trained on LEVIR-CD). Moreover, our dataset demonstrated improved consistency over domestic aerial datasets, which often suffer from heterogeneous resolutions and limited scalability for long-term monitoring. By leveraging high-resolution satellite imagery, our dataset provides a robust alternative to both overseas and domestic aerial datasets, enabling precise urban monitoring with reduced reliance on aerial surveys. It serves as a critical resource for advancing BCD research in South Korea. Future research will focus on automating the labeling process, expanding temporal coverage, and improving model performance through reinforcement learning on pre-trained models using this dataset.

**Keywords:** Building change detection; Satellite imagery; Deep learning; Remote sensing; Convolutional neural networks

## 1. 서론

변화 탐지(change detection)는 이미지 분석 분야 중 하나로 두 개 이상의 이미지를 비교하여 시간적, 공간적 차이에서 발생한 변화를 식별하는 기술이다(Singh, 1989). 원격탐사 분야에서는 서로 다른 시기에 획득된 위성 영상과 항공 사진을 활용하여 특정 지역의 시간에 따른 변화를 식별하며 이러한 방법은 환경 모니터링, 재난 관리, 도시 계획, 농업 등 다양한 분야에서 활용된다(Dueker and Horton, 1972). 최근 도시화의 가속화와 딥러닝 및 이미지 분석 방법의 발전에 따라 변화 탐지 기술의 중요성과 활용도가 꾸준히 증가하고 있다(Shafique et al., 2022).

전통적인 변화 탐지 방법은 크게 픽셀 기반과 객체 기반 방법으로 구분된다. 픽셀 기반 방법은 개별 픽셀의 분광 정보를 비교하여 이미지 차분(image differencing), 비율 기반 방법(image ratioing), 주성분 분석(principal component analysis), 다변량 변화 탐지(multivariate alteration detection) 등을 통해 변화를 식별한다(Singh, 1989). 이 방법은 계산이 단순하고 직접적인 변화 탐지가 가능하지만 픽셀 간 공간적 관계나 시간적 맥락을 충분히 반영하지 못해 노이즈에 취약하며 조명 변화나 계절적 요인으로 인한 오탐지 가능성이 크다(Benedek and Szirányi, 2009). 반면 객체 기반 방법은 영상을 의미 있는 객체 단위로 분할한 후 개별 객체의 특징(형태, 색상, 질감 등)을 분석하여 변화를 탐지한다(Blaschke et al., 2016). 이 방법은 공간적 맥락을 반영할 수 있어 세밀한 변화 탐지가 가능하며 고해상도 영상 분석에 효과적이다. 그러나 객체 분할(segmentation) 단계에서 파라미터 설정이 결과에 큰 영향을 미치며 수작업으로 설계된 특징에 의존하여 복잡한 환경에서는 일반화가 어렵다는 한계가 있다(Daudt et al., 2018).

최근 인공지능(artificial intelligence, AI) 기술의 급격한 발전과 빅데이터에 대한 접근성 향상으로 전통적인 변화 탐지 기법의 한계를 극복하는 딥러닝 기반 방법론이 활발히 연구되고 있다(Zhu et al., 2017). 특히 합성곱 신경망(convolutional neural network, CNN)과 트랜스포머(transformer) 기반 모델들이 변화 탐지 성능을 향상시키고 있다. CNN은 이미지 내 특징을 합성곱(convolution)과 풀

링(pooling) 연산을 통해 추출하고 복잡한 패턴을 점진적으로 학습하는 구조로(LeCun et al., 1989) 국소적인 특징 학습에 강점이 있어 초기 딥러닝 기반 변화 탐지 연구부터 널리 활용되어 왔다. 변화 탐지에서는 영상 간의 시계열 변화를 학습하며 convolutional block attention module과 같은 attention 메커니즘을 활용하여 공간적 및 채널 방향에서 중요한 특징을 강조함으로써 정확도를 높인다(Woo et al., 2018). 대표적인 CNN 기반 변화 탐지 모델로는 STANet(Chen and Shi, 2020)과 SNUNet-CD(Fang et al., 2022) 등이 있다.

트랜스포머는 원래 자연어 처리 분야에서 시작되어(Vaswani et al., 2017) 대형 언어 모델로 발전하면서 탁월한 성능을 보이며 그 효율성과 확장 가능성을 입증받았으며(Brown et al., 2020) vision transformer (ViT)의 발전과 함께 컴퓨터 비전 및 원격탐사 분야에서도 활발히 연구되고 있다. ViT 기반 변화 탐지 모델은 self-attention 메커니즘을 활용하여 공간적-시간적 관계를 효과적으로 학습하며 전역적 문맥을 잘 반영한다(Chen et al., 2022). CNN 기반 모델이 국소적 특징을 주로 학습하는 반면 ViT는 전체 이미지에서 중요한 패턴을 전역적으로 학습하여 더욱 정밀한 변화 탐지가 가능하다. 대표적인 ViT 기반 변화 탐지 모델로는 bitemporal image transformer(Chen et al., 2022), ChangeFormer(Bandara et al., 2022), Changer 시리즈(Fang et al., 2023) 등이 있다.

모델 구조뿐만 아니라 학습 데이터의 양과 질은 변화 탐지 정확도에 직접적인 영향을 미친다(Peng et al., 2019). 딥러닝 기술의 발전과 지구 관측 위성의 증가로 인해 고해상도 위성 빅데이터에 대한 접근성이 크게 향상되었다. WorldView, Pleiades, GeoEye와 같은 다중 분광 고해상도 위성의 발사로 더욱 풍부한 시공간적 정보를 활용할 수 있게 되었으며(Loghin et al., 2020) 이는 딥러닝 기반 고해상도 위성 영상 변화 탐지 연구를 가속화하고 도시화 모니터링, 재난 대응, 환경 변화 감지 등 다양한 응용 분야에서의 활용 가능성을 높이고 있다(Yin et al., 2023).

기존 변화 탐지 연구들은 주로 Google Earth(Google, Mountain View, CA, USA), Land Information New Zealand(LINZ)와 같은 해외 플랫폼에서 제공하는 위성 영

상 자료나 특정 지역에 대한 항공 또는 위성 영상을 주로 활용 해 왔다. 변화 탐지 모델 개발에 활용되는 대표적인 공개 데이터셋으로는 WHU-CD (Ji et al., 2019), LEVIR-CD (Chen and Shi, 2020), SYSU-CD (Shi et al., 2022) 등이 있다 (Parelius, 2023). Table 1은 대표적인 공개 변화 탐지 데이터셋에 대한 제원이다. WHU-CD는 2011년 발생한 뉴질랜드 크라이스트처치 지역에서 발생한 대지진 이후 도시 복구 과정을 기록한 항공 영상을 기반으로 구축된 데이터셋이다. 지진 발생 이후 약 1년 후인 2012년과 복구가 상당 부분 진행된 2016년에 촬영된 항공 영상으로 구성되어 있다. 원본 항공 이미지는 0.075 m/pixel의 매우 높은 공간 해상도를 가지지만 데이터의 효율적 저장과 배포, 연산 자원 부담을 고려하여 최종 사용자에게는 0.3 m/pixel 공간 해상도의 다운샘플링된 버전이 제공된다. 이러한 특성과 품질 덕분에 건물 변화 탐지 뿐만 아니라 지진 피해 분석, 재해 복구 모니터링 등에도 활용된다. LEVIR-CD는 미국 텍사스 주를 중심으로 구축된 위성 영상 데이터셋이다. 2002년부터 2018년 사이의 위성 영상을 기반으로 하며 Google Earth API를 통해 수집되었다. 수집된 영상은 0.5 m/pixel의 공간 해상도를 가지며 도시화 과정에서 급격한 변화를 겪은 주도인 오스틴 외에도레이크웨이, 비 케이브 등 여러 도시를 포함하고 있다. 이러한 지역들은 도시 개발과 재건축이 활발히 진행되는 지역으로 건물의 신축과 철거와 같은 인위적 변화가 빈번히 발생한다. 또한 영상 쌍의 간격이 5년에서 14년으로 다양하여 도시 개발의 장기적 변화와 단기적 변화를 모두 분석할 수 있다는 특징을 갖고 있어 도시 개발 분석과 건물 변화 알고리즘 등에 활용된다. SYSU-CD는 홍콩 지역을 중심으로 2007년부터 2014년까지의 기간 동안 수집된 항공 영상을 기반으로 하며 0.5 m/pixel의 공간 해상도를 가진다. 도시 지역의 신축 및 기존 건축물뿐 아니라 교외 개발, 해안 지역 등 다양한 변화 사례를 포함한다.

변화 유형의 다양성을 가진 특성으로 식생 변화, 해상 건설 등 복합적인 양상을 가진 변화 탐지 연구에 활용된다.

국내 데이터셋으로는 한국지능정보사회진흥원(National Information Society Agency, NIA)에서 제공하는 AI 기반 국립공원 변화 탐지 모니터링 플랫폼을 위해 구축된 토지 피복 AI 학습용 데이터셋(National Park Change Detection Dataset, NPCD; NIA, 2023)과 항공 영상 도시 건물 변화 탐지 데이터셋(Urban Building Change Detection from Aerial Imagery, UBCD; NIA, 2022) 등이 존재한다. NPCD의 경우 건물, 도로, 논, 밭, 벌목 대상지 등을 분류한 항공/위성 복합 영상 데이터셋으로 국립공원 내 변화를 효율적으로 탐지하기 위한 토지 피복 자동 분할 및 변화 지역 탐지 알고리즘 개발 등에 이용된다. UBCD는 국내 도시에서의 건축물 변화를 탐지하는 AI 기술 개발을 위해 제작되었다. 특히 도시 안전을 위협하는 불법 건축물의 적발 과정이 단축되도록 육안 식별 대신 변화 탐지 알고리즘을 개발하는 데 중점을 두었다.

해외의 대표적인 세 가지 예시를 포함한 기존 변화 탐지 데이터셋들은 대부분 연구 목적의 자유로운 사용을 허용하며 GitHub (GitHub, San Francisco, CA, USA) Google Drive (Google) 등을 통해 공개적으로 접근이 가능하다. 이들 데이터셋은 전후 시기의 위성 영상을 포함하고 정답 레이블 및 공식 문서까지 함께 제공함으로써 다양한 변화 탐지 모델의 벤치마크 표준으로 널리 활용되고 있다. 그러나 이들 데이터셋은 일부 부정확한 레이블이 포함되어 있으며 특정 지역에 국한된 구성이 많다는 한계가 있다.

우리나라는 좁은 국토 면적, 높은 건물 밀집도, 아파트 중심의 도시 구조 등 고유한 지리적, 도시적 특성을 가지고 있어 기존 공개 데이터셋과 이를 기반으로 훈련된 모델은 이러한 환경을 충분히 반영하지 못하는 한계가 존재한다. 특히 기존

**Table 1.** Public change detection datasets

Dataset	Period	Spatial resolution	Region	Image size (pixel)	Image pairs	Source
WHU-CD	2012-2016	0.3 m/pixel	New Zealand	512×512	1,960	Aerial photos
LEVIR-CD	2002-2018	0.5 m	USA	1,024×1,024	637	Google Earth
SYSU-CD	2007-2014	0.5 m	Hong Kong	256×256	20,000	Aerial photos
NPCD	2021-2022	0.1-30.0 m	South Korea	1,024×1,024	50,000	Various
UBCD	2015-2020	0.1 m	South Korea	1,508×754	50,779	Aerial photos

데이터셋은 상대적으로 넓은 토지 면적과 개별 건물의 윤곽이 명확한 해외 도시를 중심으로 구축되어 있어 고층 건물이 밀집한 국내 도시 환경에서는 적용에 제약이 따른다.

국내에서 구축된 데이터셋의 경우에도 산림이나 하천 등 비도시 지역을 포함하는 경우가 많고 다양한 센서 및 해상도의 항공 영상으로 구성되어 있어 지속적이고 일관된 활용에 어려움이 있다. 항공 영상을 수집하기 위해서는 전문 촬영 장비를 탑재한 항공기나 드론을 활용해야 하며 정밀한 촬영 계획과 경로 설정이 필요하다(Kang et al., 2014). 이러한 절차는 높은 운영 비용과 많은 인적 자원을 요구하며 결과적으로 즉각적인 데이터 확보가 어렵고 정기적인 데이터 갱신도 제한적이라는 문제를 야기한다.

이러한 한계를 극복하고 국내 지리적 특성을 반영한 변화 탐지 연구를 수행하기 위해서는 최근 2021년 3월 발사된 차세대 중형 위성(compact advanced satellite, CAS) 1호인 국토위성(CAS500-1) 영상을 활용한 고해상도 건물 변화 탐지(building change detection, BCD) 데이터셋 구축이 필요하다. 또한 기존 데이터셋들은 주로 Google Earth 또는 특정 시기의 위성/항공 영상을 기반으로 하여 지속적인 영상 수집이 어려운 점과 항공 영상 촬영 자체가 불가능한 지역의 존재를 고려할 때 국토위성과 같은 한국형 위성의 특성을 반영한 데이터셋의 필요성이 더욱 강조된다.

본 연구에서는 국토정보플랫폼(National Geographic Information Institute, 2023)을 통해 수집한 국토위성 영상을 이용하여 국내 도시 환경에 적합한 변화 탐지 데이터셋을 구축하였다. 이를 통해 국내의 건물 변화 양상을 효과적으로 반영하고 기존 공개 데이터셋의 한계를 보완하고자 하였다. 또한 구축된 데이터셋의 신뢰성과 유용성을 평가하기 위해 최신 변화 탐지 딥러닝 모델 중 하나인 ChangeMamba(Chen et al., 2024)를 활용하여 검증을 수행하였으며 특히 기존 데이터셋으로 학습된 모델과의 교차 검증으로 차이를 식별하고자 하였다. 이를 통해 국토위성 기반 변화 탐지 데이터셋이 국내 건축 환경에 특화된 변화 탐지 연구에 기여할 수 있음을 확인하였다.

## 2. 연구 자료 및 방법

### 2.1 연구 자료

본 연구에서는 2021년 3월 발사된 국토위성의 영상 데이터를 활용하였다. 국토위성은 국내 최초의 국토 관측 전용 위성으로 국토 모니터링, 3차원 공간정보 구축, 도시 계획, 환경 변화 분석, 재난 대응 등 다양한 목적으로 설계되었다. 이 위성에는 고해상도 광학 센서인 advanced earth imaging sensor system-compact (AEISS-C)가 탑재되어 있으며 해당 센서는 450-900 nm 파장 범위에서 4개의 분광 대역(red, green, blue, near-infrared)을 감지한다. AEISS-C 센서는 2 m 공간 해상도의 다중 분광 영상과 0.5 m 공간 해상도의 전정색(panchromatic) 영상을 동시에 제공하는데 이는 기존 해외의 상용 위성과 비교하여 경쟁력 있는 해상도이다. 국토위성의 관측 폭은 약 12 km로 4.6일의 재방문 주기를 통해 동일 지역에 대한 주기적 관측이 가능하다.

국토지리정보원 국토위성센터에서는 국토위성 다중 분광 영상을 pan-sharpening 처리를 통해 0.5 m 공간 해상도의 고해상도 다중 분광 영상을 생성한다. 이를 국토정보플랫폼(<https://map.ngii.go.kr>)을 통해 무료로 제공하고 있는데 이는 세계적으로도 유례가 드문 고해상도 위성 영상의 공공 서비스 사례로 국내 원격탐사 연구 및 산업계에 중요한 공간 정보 인프라를 제공하고 있다.

본 연구에서는 BCD 인공지능 모델 개발을 위한 학습용 데이터셋 구축을 목적으로 2021년부터 2024년까지 약 4년간의 국토위성 영상의 정사/기하 보정이 완료된 Level 2G를 활용하였다. 특히 건물 구조의 시각적 특성을 효과적으로 탐지하기 위해 0.5 m 해상도의 가시광선 영역 3개 밴드(red, green, blue)를 선정하였다. 이러한 고해상도 영상은 도시 내 건물의 변화 양상을 세밀하게 관찰하고 AI 기반 변화 탐지 알고리즘의 학습 및 검증에 적합한 자료로 판단되었다.

### 2.2 자료 수집


국토위성 영상 기반의 변화 탐지 데이터셋 구축을 위해 다양한 요소를 종합적으로 고려하여 적합한 변화 전후 영상 쌍

을 선택하였다. 첫째, 변화 탐지를 효과적으로 수행하기 위해 영상 간 충분한 시간적 간격을 확보하였다. 구체적으로는 건물 변화가 명확하게 관찰될 수 있도록 최소 6개월에서 최장 3년의 시간 간격을 가진 영상 쌍을 활용하였다.

둘째, 위성 촬영 시의 기하학적 특성, 특히 roll tilt 값을 주요 선정 기준으로 고려하였다. Roll tilt 값은 위성 센서의 촬영 각도를 의미하며 이 값이 클수록 건물의 측면이 과도하게 노출되어 동일 건물의 시계열적 변화 탐지를 어렵게 만든다(Harinath et al., 2008). Fig. 1은 서로 다른 roll tilt 값(0.34°, 11.83°, 26.68°)으로 촬영된 영상의 시각적 차이와 건물 높이에 따른 영향을 보여준다.

Fig. 1A, D는 가장 낮은 roll tilt 값(0.34°)을 갖는 영상으로 건물 높이와 관계없이 연직에 가깝게 촬영되어 시계열 분석에 최적화되어 있다. Fig. 1B, E는 중간 수준의 roll tilt 값(11.83°)을 갖는 영상으로 낮은 건물은 비교적 안정적으로 촬

영되었으나 고층 건물의 경우 측면이 상당 부분 노출되어 변화 탐지의 정확도를 저하시킬 수 있다. Fig. 1C, F는 높은 roll tilt 값(26.67°)을 갖는 영상으로 모든 건물 유형에서 촬영 각도의 영향이 뚜렷하게 나타나 정확한 변화 탐지에 상당한 제약을 초래한다. 이러한 촬영 각도 차이에 따른 정확도 저하를 최소화하기 위해 데이터셋 구축 대상 지역 선정 시 roll tilt 값의 차이가 작은 영상 쌍을 우선적으로 고려하였다. 특히 고층 건물이 밀집된 도시 지역에서는 roll tilt 값의 차이가 10° 이하인 지역을 선택함으로써 촬영 각도 차이로 인한 오차를 최소화하고 변화 탐지의 정확성을 높이고자 하였다. 상기 선정 기준을 적용하여 서울, 대전 등 전국의 다양한 도시 환경을 포함하는 총 27개의 지역을 최종 선정하였고 국토정보플랫폼을 통해 자료를 수집하였다.



**Fig. 1.** Differences in building images caused by roll tilt angle and building height. (A) Low-rise, near-Nadir (0.34°). (B) Low-rise, medium roll tilt angle (11.83°). (C) Low-rise, high roll tilt angle (26.67°). (D) High-rise, near-Nadir (0.34°). (E) High-rise, medium roll tilt angle (11.83°). (F) High-rise, high roll tilt angle (26.67°).

## 2.3 데이터셋 구축

수집된 국토위성 영상으로부터 건물 변화 탐지 AI 모델 학습에 최적화된 데이터셋 구축 과정은 영상 전처리, 레이블링, 패치 추출 및 최적화의 세 단계로 진행되었다.

첫 번째 단계인 영상 전처리 과정에서는 red, green, blue (RGB) 밴드 영상에 대해 밴드 합성 작업을 수행하여 RGB 합성 영상을 제작하였다. RGB 합성 영상은 인간의 시각적 인식 체계와 유사하여 직관적인 해석이 가능하며 위성 영상 기반 변화 탐지 연구에서 표준적으로 활용되는 데이터셋 형태이다 (Büyükdemircioğlu et al., 2022).

이어서 서로 다른 시기에 촬영된 영상 간의 정밀한 공간적 정합을 위해 Georeferencer 도구(QGIS, Grüt, Switzerland)를 활용하여 상대적 기하 보정을 수행하였다. 이 과정에서는 약 20개의 기준점(ground control points)을 영상 전체에 균등하게 분포시켜 선정하였고 2차 다항식(polynomial) 변환 모델을 적용하였다. 2차 다항식 기반 기하학적 모델링은 복잡한 지형 왜곡을 효과적으로 보정하면서도 계산 효율성이 높아 원격탐사 자료의 기하 보정에 널리 활용되고 있다 (Zitová and Flusser, 2003). 이러한 정밀 기하 보정 과정을 통해 서로 다른 시점의 영상 간 기하학적 일치성을 확보하고 픽셀 단위의 정확한 변화 탐지가 가능한 기반을 마련하였다.

두 번째 단계인 레이블링(labeling) 과정에서는 상대 기하 보정이 완료된 두 시기의 영상을 육안으로 비교하여 건물의 신축, 증축, 철거 등 변화가 발생한 영역을 식별하고 이를 벡터 형식의 폴리곤으로 정밀하게 구획하였다. 이 과정에서는 건물의 경계를 명확히 구분하여 픽셀 단위의 정확한 변화 레이블을 생성하는 데 주력하였다.

세 번째 단계에서는 생성된 레이블 데이터와 RGB 영상을 기반으로 학습 데이터 최적화 작업을 수행하였다. 먼저 전체 영상을 256×256 픽셀 크기의 균일한 그리드로 분할한 후 변화가 포함된 영역만을 선별적으로 추출하여 학습용 패치를 생성하였다. 해당 크기는 연산 효율성과 최신 변화 탐지 모델과의 호환성을 종합적으로 고려하여 설정하였다. 본 연구의 검증에 사용된 모델 또한 해당 패치 크기 내에서 효과적으로 전역적 문맥을 학습하도록 설계되었다. 이와 같이 패치를 생성하고 추출하는 과정은 AI 모델의 입력 요구 사항에 부합되

는 규격화된 데이터를 제공함과 동시에 변화가 없는 영역을 제외함으로써 클래스 불균형 문제를 완화하고 학습 효율성을 높이는 효과가 있다.

추가적으로 딥러닝 최적화된 형태로 변환하기 위해 히스토그램 스트레칭(histogram stretching) 기법을 적용하였다. 이 기법은 영상의 히스토그램 분포를 재조정하여 명암 대비를 향상시키는 방법으로 변화 영역의 시각적 식별성을 높이는 데 효과적이다. 이를 통해 모델이 중요한 변화 특징을 더 명확하게 학습할 수 있도록 데이터 품질을 최적화하였다.

## 2.4 데이터셋 검증

### 2.4.1 변화 탐지 모델 선정

구축된 국토위성 기반 변화 탐지 데이터셋의 실효성을 평가하기 위해 대표적인 공개 변화 탐지 데이터셋인 LEVIR-CD, WHU-CD 등에서 최고 수준의 정확도를 보인 딥러닝 기반 변화 탐지 모델인 ChangeMamba (Chen et al., 2024)를 활용하였다. ChangeMamba는 기존 CNN 및 ViT 기반 모델과 비교하여 연산 효율성과 전역적 문맥 학습 능력이 뛰어나며 고해상도 위성 영상 분석에 최적화된 구조적 특성을 갖추고 있다.

ChangeMamba는 state space model을 기반으로 하는 Mamba (Gu and Dao, 2023) 아키텍처를 시각적 데이터 처리에 적합하도록 확장한 Visual Mamba (VMamba; Liu et al., 2024)를 인코더의 핵심 구성 요소로 활용한다. 이 VMamba 기반 인코더는 visual state space (VSS) 블록을 통해 입력 이미지의 전역적인 공간 문맥 정보를 효과적으로 학습한다. 디코더는 spatiotemporal state space 블록을 사용하여 다중 시간 특징 간의 시공간적 관계를 모델링한다. 또한 다단계 특징 추출(multi-stage feature extraction) 방식을 통해 인코더-디코더 내에서 점진적으로 고해상도 특징을 복원함으로써 정밀한 변화 탐지가 가능하다. Fig. 2는 본 연구에서 사용한 ChangeMamba BCD 모델의 디코더 구조로 융합된 특징을 최종 이진 변화 탐지 맵으로 복원하는 과정을 보여준다.

특히 VSS 모델의 장점은 이미지 전체의 공간적, 시간적 문맥 정보를 효과적으로 학습할 수 있다는 점이다(Guo et al.,

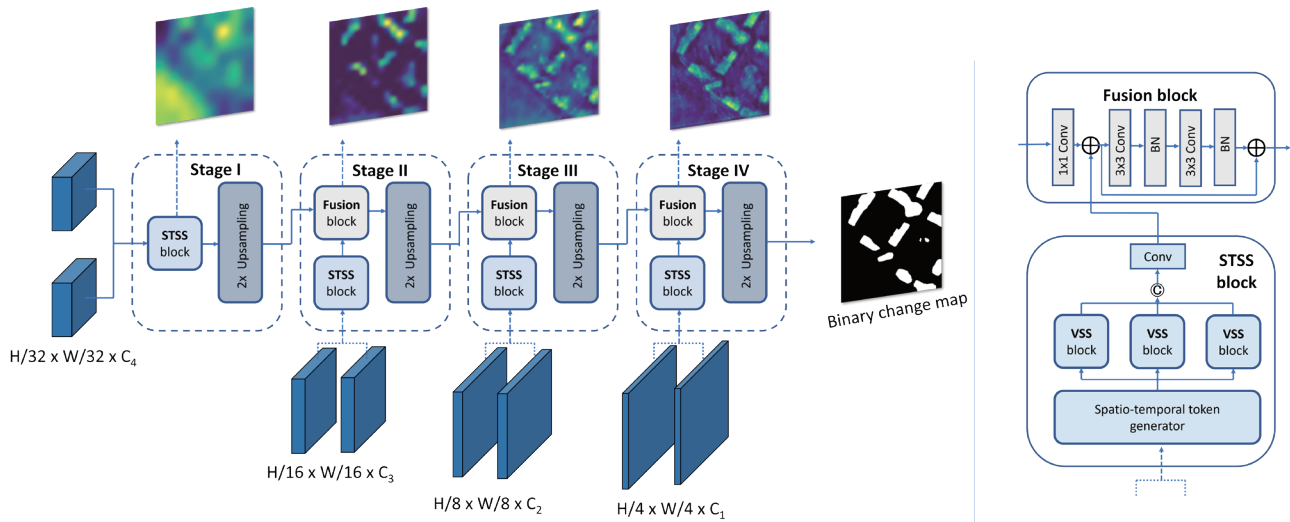


Fig. 2. The structure of the decoder used in MambaBCD. Modified from Chen et al., 2024. Conv, convolution; STSS, spatiotemporal state space; VSS, visual state space; BN, batch normalization.

2025). 이러한 특성으로 인해 ChangeMamba는 이진 변화 탐지를 비롯한 다양한 변화 탐지 작업에서 기존 모델들을 능가하는 성능을 보여주었다(Chen et al., 2024). 본 연구에서는 ChangeMamba의 세 가지 버전(Tiny, Small, Base) 중 연산 효율성과 성능 간의 균형을 고려하여 Small 모델을 선택하여 실험을 진행하였다.

### 2.4.2 실험 설계 및 평가 방법

모델 학습 안정성과 일반화 성능을 고려하여 생성 및 정리된 데이터를 8:2 비율로 훈련 및 테스트 세트로 분할하였으며 최종적으로 3,042쌍의 훈련용 데이터, 761쌍의 테스트용 데이터를 구성하였다. 추가적으로 데이터셋의 비교 성능 및 일반화 능력을 평가하기 위해 해외 위성 영상 기반 데이터셋인 LEVIR-CD, 항공 영상 기반 데이터셋인 SYSU-CD 그리고 국내 항공 영상 기반 데이터셋인 UBCD를 활용하여 모델 훈련 및 교차 테스트를 진행하였다. UBCD의 경우 데이터 양을 고려하여 준주거 지역과 준공업 지역으로 선별하여 훈련 및 검증 데이터로 활용하였다. 모든 실험에서 과적합(overfitting)과 과소적합(underfitting)을 방지하기 위해 조기 종료(early stopping) 기법을 적용하였다. 이 방법은 검증 세트에서의 손실 함수 값이 일정 기간 동안 개선되지 않을 경우 학습을 자동으로 중단하여 모델의 일반화 성능을 극대화한다.

모델의 변화 탐지 성능을 정량적으로 평가하기 위해 재현율(recall), 정밀도(precision), F1 점수(F1 score), intersection over union (IoU), kappa와 같은 지표를 활용하였다. 재현율은 실제 변화가 발생한 지역 중 모델이 정확히 식별한 비율을 나타내며 높은 재현율은 모델이 변화 영역을 놓치지 않고 잘 탐지함을 의미한다. 정밀도는 모델이 변화가 있다고 예측한 영역 중 실제로 변화가 발생한 영역의 비율을 나타낸다. F1 점수는 재현율과 정밀도의 조화 평균으로 두 지표 간의 균형을 평가하는 데 사용되는 지표이다. 이 값이 높을수록 모델이 변화를 놓치지 않으면서도 오탐지를 최소화함을 의미한다. IoU는 예측한 변화 영역과 실제 변화 영역의 교집합을 합집합으로 나눈 값으로 변화 영역 식별의 정확도를 평가하는 핵심 지표이다. 높은 IoU 값은 모델의 예측이 실제 변화를 공간적으로 정확하게 탐지함을 의미한다. Kappa 계수는 모델의 성능을 우연에 의한 예측과 비교하여 평가하는 지표이다. Kappa 값이 1에 가까울수록 모델의 예측이 우수함을 의미하고 0에 가까울수록 우연에 의한 예측과 유사함을 나타낸다. 일반적으로 0.75 이상의 kappa 값은 높은 신뢰도를 의미한다.

이러한 평가 지표들은 다음과 같은 식으로 계산된다(Eq. 1-5).

$$Recall = \frac{TP}{TP + FN} \quad \text{Eq. 1}$$

$$Precision = \frac{TP}{TP + FP} \quad \text{Eq. 2}$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad \text{Eq. 3}$$

$$IoU = \frac{TP}{TP + FP + FN} \quad \text{Eq. 4}$$

$$Kappa = \frac{P_o - P_e}{1 - P_e} \quad \text{Eq. 5}$$


여기서 true positive는 변화 지역을 정확히 탐지한 경우, false negative는 실제 변화가 일어난 지역을 탐지하지 못한 경우, false positive는 변화가 없는 지역을 변화 지역으로 잘못 탐지한 경우를 의미한다. Eq. 5에서  $P_o$ 는 모델의 실제 정확도,  $P_e$ 는 우연에 의한 정확도를 나타낸다.

모델의 정성적 평가를 위해 예측 결과에 대한 육안 검수도 함께 수행하였으며 국토위성 데이터셋과 기존 공개 데이터셋 간의 결과 비교를 통해 구축된 데이터셋의 활용 가능성을 종합적으로 평가하였다.


### 3. 연구 결과

#### 3.1 데이터셋 구축 결과

앞서 기술한 방법론에 따라 국토위성 영상 기반의 BCD를 위한 학습용 데이터셋을 구축하였다. 총 27개 지역에 대해 체계적인 전처리 과정과 정밀한 레이블링 작업을 수행한 결과 최종적으로 3,803쌍의 BCD 데이터셋이 완성되었다. Fig. 3은 본 연구를 통해 최종 구축된 변화 탐지 데이터셋의 대표적인 변화 사례를 보여준다. Fig. 3A는 건물이 새롭게 건설된 경우, Fig. 3B는 건물이 철거된 경우, Fig. 3C는 공사 중인 경우를 나타내며 Fig. 3의 각 행은 변화 전 영상(T1), 변화 후 영상(T2) 그리고 변화 영역 레이블(ground truth, GT)로 구성되어 있다. 데이터셋은 주택, 아파트와 같은 주거용 건물뿐만 아니라 공장, 학교, 상업 시설 등 다양한 유형의 건물이 포함된 지역에서 신축, 철거, 증축 및 개축 등 다양한 변화 유형을 포괄하도록 구축되었다. 이러한 변화 유형과 건물 특성의 다양성은 모델이 실제 국내 도시 환경에서 발생하는 다양한 변화 패턴을 효과적으로 학습하고 일반화할 수 있는 토대를 마련해줄 것으로 기대한다.



**Fig. 3.** Examples of changed buildings. Columns represent different change types. (A) Newly constructed, (B) demolished, and (C) under construction. Rows represent image types are T1, T2, and GT. GT, ground truth.



**Fig. 4.** Qualitative assessment of building change detection using the ChangeMamba model trained on the CAS500-1 BCD datasets. (A) Large-scale construction. (B) Small-scale construction. (C) Building demolition. (D) Missed detection due to low contrast (red square). (E) False detection due to shadows or low light (red square).

### 3.2 구축 데이터셋을 이용한 AI 기반 변화 탐지 결과

Fig. 4는 본 연구에서 구축한 국토위성 데이터셋을 활용하여 ChangeMamba 모델을 학습시키고 테스트한 결과 중 서로 다른 유형의 건물 변화에 대한 주요 사례를 보여준다. 각 사례는 T1, T2, GT 그리고 모델이 예측한 변화 영역(predicted)으로 구성되어 있다.

Fig. 4A는 농경지에서 대규모 건축물의 신축 공사가 진행 중인 사례로 모델이 복잡한 건물 구조의 윤곽을 정확히 탐지하였다. Fig. 4B는 소규모 건물이 신축된 사례로 작은 면적임에도 변화 영역을 효과적으로 식별하였다. 그 밖에 기존 건물이 철거된 경우에도 Fig. 4C에서 보는 바와 같이 건물의 선형 구조의 변화를 정확히 탐지하였다. 반면 일부 사례에서는 모델의 한계점도 발견되었다. Fig. 4D는 실제 변화 지역을 탐지하지 못한 미탐지 사례 예시로 변화가 발생한 건물의 규모가 작고 주변의 다른 건물 및 식생과 색상, 질감이 유사하여 변화 특징이 뚜렷하지 않은 경우에 주로 발생하였다. Fig. 4E는 변화가 없는 지역을 변화로 판단한 오탐지 사례로 주로 그림자, 저조도로 인해 분광 특성이 달라진 영역을 잘못 탐지하는 경향을 보인다. 이와 같은 탐지 실패 사례 또한 일부 존재하여 개선의 여지는 남아 있었다. 그럼에도 불구하고 육안 평가 결과 변화 탐지 모델은 GT 이미지상에서 레이블링된 변화 지역과 높은 일치도를 보였으며 건물의 크기, 형태, 변화 유형(신

축, 철거, 개축 등)에 관계없이 일관된 성능을 나타냈다. 특히 변화의 규모가 작거나 경계가 모호한 지역에서도 비교적 높은 정확도로 변화를 탐지하였으며 이는 국토위성 데이터셋이 국내 건축물의 특성을 잘 반영하도록 구축되었음을 시사한다.

국토위성 데이터셋 및 주요 비교 데이터셋을 활용한 ChangeMamba 모델의 정량적 성능 평가 결과는 Table 2와 Table 3에 요약되어 있다.

Table 2는 각 데이터셋을 훈련과 테스트에 동일하게 사용했을 때의 성능을 보여준다. 국토위성 데이터셋의 경우 재현율(recall) 0.76, 정밀도(precision) 0.83, F1 점수 0.79, IoU 0.66, kappa 계수 0.77의 결과를 나타냈다. 이는 SYSU-CD, LEVIR-CD에 비해 다소 낮은 수치이나 UBCD와는 유사한 수준의 성능을 보였다. 국토위성 데이터셋이 기존 공개 데이터셋보다 다소 낮은 성능을 나타낸 이유는 크게 세 가지 요인으로 설명할 수 있다. 첫째, 구축된 데이터의 양적 차이로 SYSU-CD와 LEVIR-CD는 각각 10,000쌍 이상의 샘플을 포함하는 반면 국토위성 데이터셋은 약 3,800쌍으로 상대적으로 규모가 작다. 둘째, 국내 도시는 고밀도 건물 배치, 다양한 건축 유형의 혼재, 복잡한 도로망 등의 특성을 가지고 있어 변화 탐지가 더 어려운 환경이다. 셋째, 소스 이미지의 품질 차이, 경사 촬영으로 인한 왜곡, 전처리 과정의 차이와 레이블링 과정에서의 정확도 등 데이터셋 구축에 있어 방법론과 환경의 차이 등이 성능에 영향을 미칠 수 있을 것으로 판단된다.

**Table 2.** Quantitative results of building change detection using ChangeMamba

Training set	Test set	Recall	Precision	F1	IoU	Kappa
CAS500-1	CAS500-1	0.76	0.83	0.79	0.66	0.77
SYSU-CD	SYSU-CD	0.78	0.87	0.82	0.70	0.77
LEVIR-CD	LEVIR-CD	0.86	0.89	0.87	0.78	0.87
UBCD	UBCD	0.75	0.82	0.78	0.64	0.78

IoU, intersection over union; UBCD, urban building change detection from aerial imagery.

**Table 3.** Performance drop due to cross-dataset testing

Training set	Test set	Recall	Precision	F1	IoU	Kappa
CAS500-1	LEVIR-CD	0.45	0.80	0.48	0.31	0.45
LEVIR-CD	CAS500-1	0.10	0.71	0.18	0.10	0.16
CAS500-1	UBCD	0.19	0.05	0.08	0.04	0.06
UBCD	CAS500-1	0.08	0.66	0.15	0.08	0.13

IoU, intersection over union; UBCD, urban building change detection from aerial imagery.

그럼에도 불구하고 국토위성 데이터셋은 정밀도(0.83) 측면에서 우수한 결과를 보였으며 이는 모델에 의해 탐지된 변화 영역 중 실제 변화가 발생한 비율이 높다는 것을 의미한다. Kappa 계수 역시 0.77로 우수한 수준을 보여 모델 예측 결과의 일관성을 잘 유지하고 있음을 확인할 수 있다. 이러한 결과는 국토위성 데이터셋이 변화 탐지 모델 학습에 적합한 구조를 가지고 있으며 향후 국토위성을 활용한 변화 탐지 연구에서 신뢰성 높은 결과를 도출할 수 있는 기반이 될 수 있음을 보여준다.

Table 3은 서로 다른 데이터셋 간의 일반화 능력을 평가하기 위한 교차 테스트 결과이다. 모든 경우에서 동일 데이터셋 내 테스트 결과와 비교하였을 때 현저한 성능 저하가 확인되었다. 이러한 교차 테스트에서의 성능 저하는 다음과 같은 다양한 요인에 기인한다. 첫째, LEVIR-CD와 같은 해외 데이터셋은 서구의 도시 계획 및 건축 양식을 반영하고 있어 국내의 고밀도 도시 환경과는 상이한 패턴을 보인다. 예를 들어 국내 아파트 단지과 같은 고층, 고밀도 주거 형태는 LEVIR-CD 데이터셋에는 찾아보기 어렵다. 둘째, 국토위성, 상용 위성, 항공 촬영 등 서로 다른 플랫폼은 각기 다른 센서 특성(분광 해상도, 신호 대 잡음비 등)을 가지며 이는 영상의 시각적 특성에 영향을 미친다. 특히 주목할 점은 UBCD 데이터셋은 동일하게 국내 지역을 대상으로 함에도 큰 성능 차이가 발생하였다. 이는 단순히 데이터의 지리적 특성보다 센서 플랫폼의 차이(위성 vs. 항공), 촬영 기하(경사 vs. 연직) 등이 변화 탐지 모델의 일반화 능력에 더 큰 영향을 미칠 수 있음을 시사한다.

#### 4. 결론

본 연구에서는 국토위성 영상을 활용한 건물 변화 탐지 GeoAI 학습용 데이터셋을 구축하고 그 유효성을 검증하였다. 촬영 기하, 시간적 간격, 지역적 특성 등을 종합적으로 고려하여 국토위성 영상을 수집하고 정밀한 상대 기하 보정, 다중 분광 영상의 밴드 합성 및 정규화, 폴리곤 기반의 레이블 데이터 제작 등 체계적인 과정을 통해 고품질의 학습 데이터셋을 구축하였다. 256×256 픽셀 크기의 패치로 구성된 본 데이터셋은 최신 딥러닝 기반 변화 탐지 알고리즘에 최적화되어 있으며 도시 계획, 재난 복구, 환경 모니터링 등 다양한 분

야에서 활용 가능하다.

특히 본 연구는 기존 해외 위성 데이터 기반 변화 탐지 데이터셋과 차별화하여 국내 위성 데이터를 활용한 데이터셋을 구축했다는 점에서 중요한 의의를 지닌다. 한국은 도시화가 급속히 진행되었고 높은 인구 밀도와 제한된 국토 면적으로 인해 용적률이 높은 고층 건물이 밀집된 독특한 도시 환경을 가지고 있다. 이러한 환경에서는 건물의 신축, 철거, 재개발이 빈번하게 발생하여 변화 탐지에 있어 더욱 정밀한 분석이 요구된다. 실험 결과를 통해 타 데이터셋을 활용한 변화 탐지 모델은 국토위성 데이터에서 일반화 성능이 저하됨을 확인하였으며 이는 데이터의 양적 차이, 국내 도시 환경의 복잡성뿐만 아니라 센서 특성과 촬영 조건 등의 차이에서 기인하는 것으로 서로 다른 데이터셋 간의 호환성이 제한적임을 명확히 보여준다. 이러한 결과는 국토위성의 특성에 최적화된 독자적인 데이터셋 구축의 필요성을 강력히 뒷받침한다.

국토위성 기반 변화 탐지 데이터셋은 높은 시간 및 공간적 신뢰성을 확보하고 지속적인 영상 수집이 가능하여 항공 데이터 및 해외 위성 영상에 대한 의존도를 줄이는 역할을 할 수 있다. 또한 앞으로 발사될 다양한 국내 위성(CAS, 다목적 실용 위성, 초소형 위성 등)의 활용성을 극대화하는 데 기여할 것으로 기대된다.

본 연구는 몇 가지 한계점도 존재한다. 첫째, 레이블 과정에서 작업자의 주관적 판단이 개입될 수 있어 향후 레이블링의 정량화 또는 자동화 기술 도입이 필요하다. 둘째, 건물의 미세한 구조적 변화, 복잡한 배경, 공사 지역의 모호함 등으로 인해 일부 지역에서 모델이 변화 탐지에 실패하는 경우가 있었다. 이는 데이터셋의 양적, 질적 측면에서의 제한과 관련이 있으며 국토위성 2호의 발사를 통해 국토위성의 운영 기간이 길어지고 데이터가 지속적으로 축적됨에 따라 점차 개선될 것으로 예상된다. 셋째, 본 연구의 성능 평가는 kappa 계수나 IoU 값과 같은 픽셀 단위 지표를 중심으로 이루어져 개별 건물 객체를 단위로 한 탐지 성능을 직접적으로 평가하지는 못하였다. 픽셀 기반 평가는 변화 영역의 전반적인 탐지율을 보여줄 수는 있으나 개별 건물의 탐지 여부를 명확히 나타내는 데는 한계가 있다. 따라서 향후 연구에서는 객체 기반의 평가 방법을 함께 도입하여 모델의 실질적인 성능을 다각적으로 분석하고 검증할 필요가 있다.

종합하면 본 연구는 국토위성 데이터를 활용한 변화 탐지 연구의 새로운 가능성을 제시하는 중요한 성과라 할 수 있다. 구축된 데이터셋은 국내 도시 환경의 특성을 반영하여 다양한 변화 탐지 모델의 개발을 위한 기반을 제공하며 향후 개선을 통해 보다 높은 신뢰성과 범용성을 갖출 것으로 기대된다. 이를 통해 국내 위성 데이터 분야의 연구 및 응용 분야에 있어서 실질적 성과를 이끌어 낼 것을 전망하며 궁극적으로 도시 계획, 환경 모니터링 등 사회의 다양한 문제 해결과 의사결정에 기여할 것을 기대한다.

## Conflict of Interest

On behalf of all authors, the corresponding author states that there is no conflict of interest.

## Funding Information

This work was supported by the Korea Agency for Infrastructure Technology Advancement (KAIA) R&D program of Digital Land Information Technology Development funded by the Ministry of Land, Infrastructure and Transportation (MOLIT) (Grant RS-2022-00142501), and by the Pukyong National University Research Fund in 2023 (202303790001).

## Data Availability Statement

The data that support the findings of this study are available on request from the corresponding author. The data are not publicly available due to privacy or ethical restrictions.

## References

- Bandara WGC, Patel VM (2022) A transformer-based siamese network for change detection. In: IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium, Kuala Lumpur Convention Centre, Kuala Lumpur, 17-22 Jul 2022 pp 207-210
- Benedek C, Sziranyi T (2009) Change detection in optical aerial images by a multilayer conditional mixed Markov model. *IEEE Trans Geosci Remote Sens* 47(10):3416-3430
- Blaschke T, Lang S, Tiede D, Papadakis M, Györi A (2016) Object-based image analysis beyond remote sensing - the human perspective. *Int Arch Photogramm Remote Sens Spatial Inf Sci XLI-B7:879-882*
- Brown T, Mann B, Ryder N, et al (2020) Language models are few-shot learners. In: *Proceedings of the 34th International Conference on Neural Information Processing Systems*, Vancouver, 6-12 Dec 2020 pp 1877-1901
- Buyukdemircioglu M, Can R, Kocaman S, Kada M (2022) Deep learning based building footprint extraction from very high resolution true orthophotos and NDSM. *ISPRS Ann Photogramm Remote Sens Spatial Inf Sci V-2-2022:211-218*
- Chen H, Shi Z (2020) A spatial-temporal attention-based method and a new dataset for remote sensing image change detection. *Remote Sens* 12(10):1662
- Chen H, Qi Z, Shi Z (2022) Remote sensing image change detection with transformers. *IEEE Trans Geosci Remote Sens* 60:1-14
- Daudt RC, Le Saux B, Boulch A, Gousseau Y (2018) Urban change detection for multispectral earth observation using convolutional neural networks. In: *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*, Valencia, 22-27 Jul 2018 pp 2115-2118
- Dueker KJ, Horton FE (1972) Urban-change detection systems: remote-sensing inputs. *Photogrammetria* 28(3):89-106
- Fang S, Li K, Li Z (2023) Changer: feature interaction is what you need for change detection. *IEEE Trans Geosci Remote Sens* 61:1-11
- Fang S, Li K, Shao J, Li Z (2022) SNUNet-CD: a densely connected siamese network for change detection of VHR images. *IEEE Geosci Remote Sens Lett* 19:1-5
- Gu A, Dao T (2023) Mamba: linear-time sequence modeling with selective state spaces. *arXiv* 2312.00752
- Guo H, Li J, Dai T, Ouyang Z, Ren X, Xia ST (2025) MambaR: a simple baseline for image restoration with state-space model. In: Leonardis A, Ricci E, Roth S, Russakovsky O, Sattler T, Varol G (eds) *Computer Vision - ECCV 2024*, vol 15076. Springer, Cham, pp 222-241
- Harinath N, Mahadevan V, Sarma KS (2008) Resourcesat-1 mission planning, analysis and operations -outline of key components. *Int J Appl Earth Obs Geoinf* 10(2):124-132
- Ji S, Wei S, Lu M (2019) fully convolutional networks for multisource building extraction from an open aerial and satellite imagery data set. *IEEE Trans Geosci Remote Sens* 57(1):574-586
- Kang JH, Myung HJ, Kwon OK, Yoon SY (2014) Analysis of high-resolution satellite imagery utilization and image processing technologies. Korea Institute of Science and Technology Information, Daejeon
- LeCun Y, Boser B, Denker JS, et al (1989) Backpropagation applied to handwritten zip code recognition. *Neural Comput* 1(4):541-551
- Liu Y, Tian Y, Zhao Y, et al (2024) VMamba: Visual state space model. In: *38th Conference on Neural Information Processing Systems*, Vancouver Convention Center, Vancouver, 10-15

Dec 2024, pp 1-12

- Loghin AM, Otepka-Schremmer J, Pfeifer N (2020) Potential of Pléiades and WorldView-3 tri-stereo DSMs to represent heights of small isolated objects. *Sensors* 20(9):2695
- National Geographic Information Institute (2023) Geospatial Information Platform. National Geographic Information Institute. <https://map.ngii.go.kr> Accessed 8 Nov 2024
- National Information Society Agency (2022) Urban building change detection dataset. AI Hub. <https://www.aihub.or.kr/aihubdata/data/view.do?dataSetSn=491> Accessed 11 Nov 2024
- National Information Society Agency (2023) National Park change detection dataset. AI Hub. <https://www.aihub.or.kr/aihubdata/data/view.do?dataSetSn=71363> Accessed 11 Nov 2024
- Parelius EJ (2023) A review of deep-learning methods for change detection in multispectral remote sensing images. *Remote Sens* 15(8):2092
- Peng D, Zhang Y, Guan H (2019) End-to-end change detection for high resolution satellite images using improved UNet++. *Remote Sens* 11(11):1382
- Shafique A, Cao G, Khan Z, Asad M (2022) Deep learning-based change detection in remote sensing images: a review. *Remote Sens* 14(4):871
- Shi Q, Liu M, Li S, Liu X, Wang F, Zhang L (2022) A deeply supervised attention metric-based network and an open aerial image dataset for remote sensing change detection. *IEEE Trans Geosci Remote Sens* 60:1-16
- Singh A (1989) Review article digital change detection techniques using remotely-sensed data. *Int J Remote Sens* 10(6):989-1003
- Vaswani A, Shazeer N, Parmar N, et al (2017) Attention Is all you need. In: 31st Conference on Neural Information Processing Systems (NIPS 2017), Long Beach, 4-9 Dec 2017 pp 1-11
- Woo S, Park J, Lee JY, Kweon IS (2018) CBAM: convolutional block attention module. In: European Conference on Computer Vision (ECCV) 2018, Munich, 8-14 Sep 2018 pp 3-19
- Yin H, Weng L, Li Y, et al (2023) Attention-guided siamese networks for change detection in high resolution remote sensing images. *Int J Appl Earth Obs Geoinf* 117:103206
- Zhu XX, Tuia D, Mou L, et al (2017) Deep learning in remote sensing: a comprehensive review and list of resources. *IEEE Geosci Remote Sens Mag* 5(4):8-36
- Zitová B, Flusser J (2003) Image registration methods: a survey. *Image Vis Comput* 21(11):977-1000

## Meta Data for Dataset

Essential		
Field	Sub-Category	
Title of Dataset	GeoAI Dataset for Building Change Detection from CAS500-1	
DOI	The data are not publicly available due to privacy or ethical restrictions	
Category	Environment	
Temporal Coverage	2021.10.-2024.06.	
Spatial Coverage	Address	South Korea
	WGS84 Coordinates	[Latitude] 32°53'13.51"N to 38°44'43.74"N [Longitude] 124°4'49.16"E to 131°48'20.61"E
Personnel	Name	Junhwa Chi
	Affiliation	Pukyong National University
	E-mail	jchi@pknu.ac.kr
CC License	CC BY-NC	
Optional		
Field	Sub-Category	
Summary of Dataset	The dataset contains labeled data for building change detection acquired from CAS500-1 images. Each data pair is composed of a pre-change RGB image (T1), a post-change RGB image (T2), and a corresponding binary mask for changed pixels (GT)	
Project		
Instrument		