

고해상도 위성영상 기반  
북한 기본공간정보 추출을 위한  
딥러닝 프레임워크 구축

- 통일·평화기반구축사업 -

(연구결과 보고서)

2022. 1.

서울대학교

# 목차

I. 사업 개요	1
1. 추진배경 및 필요성	1
2. 연구 목표	3
II. 사업 내용	5
1. 딥러닝 학습데이터셋 구축	5
가. 오픈소스 OpenStreetMap 수집	5
나. 고해상도 위성영상 수집	8
다. 패치 기반의 딥러닝 학습데이터셋 구축	12
2. 기본공간정보 추출 딥러닝 네트워크 개발	14
가. 공간정보 자동생성 딥러닝 네트워크 개발	14
나. 네트워크 시범 적용 및 검증	19
3. 기본공간정보 데이터셋 구축	25
가. 대상 지역의 기본공간정보 생성	25
나. 생성된 기본공간정보와 OpenStreetMap 비교분석	28
4. 연구결론	29
가. 대상 지역의 기본공간정보 생성	29
III. 사업 성과 및 예산	31
1. 사업 성과	31
2. 예산집행	33
참고문헌	35

## 표 차례

표 1. 북한 공간정보 구축 현황 요약 .....	2
표 2. 사업의 세부 목표와 내용 .....	3
표 3. 사업의 연구 추진 일정 .....	4
표 4. 활용된 GeoEye-1 위성영상의 세부사항 .....	9
표 5. 활용된 Worldview-2 위성영상의 세부사항 .....	10
표 6. 세 가지 semantic segmentation 네트워크 구조 .....	16
표 7. 학습 파라미터 및 실험 환경 .....	17
표 8. GeoEye-1 영상 기준 세 가지 네트워크의 분류 정확도 비교 .....	21
표 9. 이종영상 적용성 검증을 위한 정확도 비교 .....	22
표 10. 개선된 네트워크의 정확도 비교 .....	24
표 11. 본 사업의 예상 성과물 요약 .....	32
표 12. 본 사업의 예산 계획 .....	33
표 13. 본 사업의 실제 예산 집행 .....	34
표 14. 본 사업의 실제 예산 집행 내용 .....	34

# 그림 차례

그림 1. 사업의 목표 .....	3
그림 2. 북한 평양시의 OSM 데이터 .....	6
그림 3. OSM과 고해상도 위성영상 비교 .....	7
그림 4. 기존 OSM과 정제된 OSM 데이터 .....	7
그림 5. Worldview-2 영상 기준 검증용 레이블 데이터 .....	11
그림 6. 패치 형태의 학습데이터 구축 방법 .....	12
그림 7. Image classification 및 semantic segmentation을 위한 딥러닝 네트워크 구조 .....	14
그림 8. 공간정보 추출을 위한 semantic segmentation 네트워크의 학습 과정 ..	15
그림 9. 정확도 평가 지표 .....	18
그림 10. 모델 학습 과정 .....	19
그림 11. GeoEye-1 영상 기준 건물 추출 적용 결과 .....	20
그림 12. 북한 평양시 건물 객체의 정답데이터 .....	20
그림 13. 평양시 일부 지역에 대한 세 가지 모델의 건물 추출 결과 비교 .....	21
그림 14. Worldview-2 영상 기준 건물 추출 결과 .....	22
그림 15. GeoEye-1 영상 기준 개선된 네트워크의 결과 .....	23
그림 16. Worldview-2 영상 기준 개선된 네트워크의 결과 .....	24
그림 17. 북한 평양시 기본공간정보 생성 결과 .....	26
그림 18. 기존 OSM과 생성된 기본공간정보 비교 .....	28
그림 19. 최종 연구 성과 요약 .....	29

# I. 사업 개요

## 1. 추진배경 및 필요성

- 현재까지 한반도 통일·평화기반구축을 위한 다양한 북한 인프라 현황파악 및 변동 분석, 통일·평화 로드맵 구축 등에 관한 연구가 진행되어왔다. 이러한 북한 인프라에 대한 분석, 관련 학술연구, 로드맵 구축 등이 성공적으로 수행되고 실효성을 가지기 위해서는, 공간정보를 바탕으로 한 북한 현황에 관한 체계적인 분석연구가 함께 수반되어야 한다.
- 한편, 물리적 접근이 어려운 북한지역의 공간정보를 취득하는 적합한 수단으로 위성영상이 활용되고 있다. 현재 운용되고 있는 위성영상으로부터 교통시설, 건축구조물, 수계, 식생과 같은 기본공간정보가 추출될 수 있으며, 이를 바탕으로 북한 주요 도시의 현황, 시계열 변화 양상, 건축물·수계·식생의 분포 및 면적과 같은 공간적 속성정보들을 분석할 수 있다.
- 국토지리정보원을 비롯한 국내 관련 기관들에서는 수치지형도, 정사영상, 수치표고, 토지피복도와 같은 다양한 북한 공간정보를 구축하여왔다(표 1). 그러나 전문가의 판독에 의존한 공간정보 생산체제로 인해 현재 구축된 북한 공간정보는 갱신주기가 일정하지 않고 최신성이 부족하며, 이로 인해 북한 관련 정책 수립과 연구에 한계가 발생한다.

표 1. 북한 공간정보 구축 현황 요약 (공간해상도 5m 이하인 경우)

제작시기	유형(축적 또는 공간해상도)	예시	
2006- 2009	정사영상(2.5m) 수치지형도(1/25,000)		
2011- 2014	연속수치지형도(1/25,000) 온맵지도, 북한지도집	정사영상	수치지형도
2015- 2019	[남북경협/철도 도로 구간 국한] 정사영상(0.5m), 수치표고(5m) 수치지형도(1/5,000) 연속수치지형도		
2016	중분류 토지피복도 (2.8m, 개성)	온맵지도	토지피복도

- 특히, 1m급의 고해상도 위성영상을 이용하면 고수준의 객체 단위 정보를 추출할 수 있으나, 전문가의 판독에 의존하는 현 생산체계상 효율성이 낮고 비용이 과대하게 발생하는 문제가 발생한다. 이 과정에서 공간정보의 노후화와 구축범위 한계가 필연적으로 발생한다.
- 따라서, 기존 생산체계를 보완할 수 있는 공간정보 자동생산체계가 개발될 필요가 있다. 특히, 영상 분류와 객체 탐지를 비롯한 다양한 영상 판독 분야에서 각광받고 있는 딥러닝 기술은 다량의 데이터를 효율적으로 분석할 수 있다는 장점을 지닌다. 이러한 딥러닝 기술에 기반하여, 지속적으로 증대되고 있는 위성영상 자료로부터 북한 공간정보를 자동으로 생산하는 체계가 연구될 필요가 있다.

## 2. 연구 목표

본 사업에서는 고해상도 위성영상과 딥러닝 기술을 활용한 북한지역 기본공간정보 추출 프레임워크를 구축한다. 이를 통해 신속성과 표준성을 갖춘 북한지역 기본공간정보 추출기술을 개발하는 것이 본 연구의 목표이다.

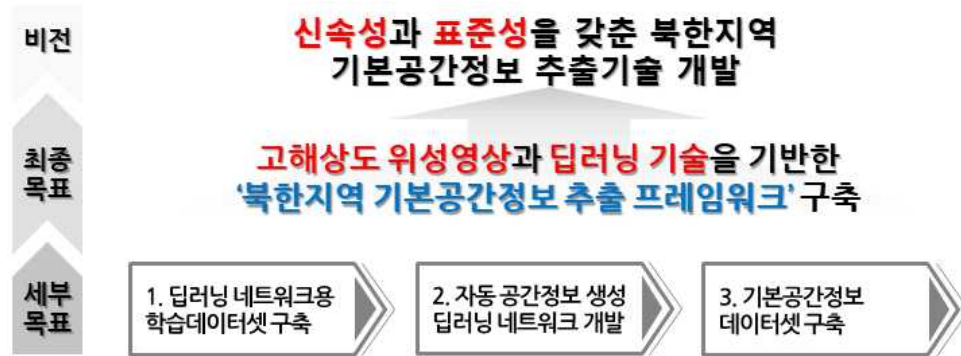


그림 1. 사업의 목표

### ○ 세부 목표

본 사업은 세 가지의 세부 목표를 가지며, 각 세부 목표의 구체적인 내용은 표 2와 같다.

표 2. 사업의 세부 목표와 내용

세부 목표	내용
1. 딥러닝용 학습데이터셋 구축	주변 화소(pixel) 정보를 최대한 활용하기 위해 패치 기반의 학습데이터를 구축한다. 학습데이터셋은 고해상도 위성영상과 OSM 데이터를 활용하여 구성한다. 1. 오픈소스 OSM 데이터 수집 2. 북한의 고해상도 위성영상 수집 3. 패치 기반의 딥러닝 학습데이터셋 구축
2. 공간정보 추출 딥러닝 네트워크 개발	고해상도 위성영상으로부터 공간정보를 효과적으로 추출할 수 있는 딥러닝 네트워크 개발한다. 1. 공간정보 자동생성 딥러닝 네트워크 개발 2. 대상 지역을 기준으로 시범 적용 및 네트워크 검증
3. 기본 공간정보 데이터셋 구축	학습데이터셋과 딥러닝 네트워크를 활용하여 북한지역 기본공간정보를 추출한다. 1. 대상 지역의 기본공간정보 생성 2. 생성된 기본공간정보와 OSM 비교분석

○ 사업의 범위

- **데이터** : 본 사업은 고해상도 위성영상의 보안성 문제와 데이터 구축량을 고려하여 해외 고해상도 위성영상 및 오픈소스 OSM 데이터를 이용하여 학습데이터셋을 구축한다. 해외 고해상도 위성영상 중 WorldView-2와 GeoEye-1을 활용하며, OSM 데이터는 벡터 형태로 취득한다.
- **대상 지역** : 다양한 공간정보가 포함된 도시 지역을 기준으로 기술 개발 및 검증을 수행한다. 사업의 대상 지역은 평양시 일대로 고해상도 위성영상의 가용성을 고려하여 선정할 예정이다.
- **기본공간정보의 범위** : 공통적으로 활용도가 높은 10개의 기본공간정보<sup>1)</sup> 중 고해상도 위성영상으로부터 추출 가능한 건축구조물(건물), 교통시설(도로), 수계, 식생의 4가지를 범위로 설정한다.

○ 연구 추진 일정

본 사업의 구체적인 연구 추진 일정은 다음과 같다.

표 3. 사업의 연구 추진 일정

사업내용	연구 추진 기간 (11개월)										
	1	2	3	4	5	6	7	8	9	10	11
<b>1. 딥러닝용 학습데이터셋 구축</b>											
1.1. 오픈소스 OSM 데이터 수집											
1.2. 북한의 고해상도 위성영상 수집											
1.3. 패치 기반의 딥러닝 학습데이터셋 구축											
<b>2. 기본공간정보 추출 딥러닝 네트워크 개발</b>											
2.1. 공간정보 자동생성 딥러닝 네트워크 개발											
2.2. 대상 지역을 기준으로 시범 적용 및 네트워크 검증											
<b>3. 기본공간정보 데이터셋 구축</b>											
3.1. 대상 지역의 기본공간정보 생성											
3.2. 생성된 기본공간정보와 OSM의 비교분석											

1) 측량기준점, 구역 경계, 교통시설, 건축구조물, 지형, 수계, 식생, 관심 지점, 영상, 격자



## II. 사업 내용

### 1. 딥러닝 학습데이터셋 구축

본 사업에서 구축하는 프레임워크의 핵심 요소인 딥러닝 네트워크는 고해상도 위성영상으로부터 기본공간정보를 자동 생성하는 역할을 한다. 딥러닝 네트워크는 고해상도 위성영상과 레이블 데이터로 이루어진 학습데이터셋으로부터 고차원의 공간적 특징 정보를 학습하여 기본공간 정보 생성을 수행한다. 이를 위해 본 사업에서는 오픈소스 방식의 무료 지도서비스인 OpenStreetMap(OSM)을 활용하여 딥러닝 학습데이터셋을 구축하였다.

#### 가. 오픈소스 OpenStreetMap 수집

##### ○ 공간정보 구축을 위한 OSM의 활용

- 현재, 전 세계적으로 Google Map을 비롯한 수많은 디지털 지도 서비스가 운용 및 활용되고 있다. 이러한 지도서비스는 세계 대부분 지역에 대한 공간정보를 효율적으로 제공한다.
- 그 중, OSM은 영국의 비영리기구 OpenStreetMap 재단에서 운영 중인 오픈소스 방식의 디지털 지도서비스로, 사용자 참여형으로 제작·갱신되고 있으며 데이터 접근이 무료로 가능한 점이 특징이다.
- OSM은 buildings, landuse, natural, railways, roads, traffic, water 등의 객체를 전 세계 대상으로 구축하고 있으며, 이는 기본공간정보 항목 중 경계(행정구역), 교통(도로, 철도, 도로시설), 수운(하천), 시설물(건물) 등에 대한 정보를 제공할 수 있다.
- 구축된 OSM 데이터는 shape 파일의 형식으로 누구나 쉽게 무료로 취득할 수 있으며, 과거 시점에 대한 자료들도 접근할 수 있다. 또한, 비접근지역인 북한에 대해서도 다양한 시기의 OSM 데이터가 구축되어있다(그림 2).

file	date	size
<a href="#">north-korea-150101-free.shp.zip</a>	2018-04-27 04:27	23336952
<a href="#">north-korea-150101-free.shp.zip.md5</a>	2018-05-03 16:26	66
<a href="#">north-korea-150101.osm.pbf</a>	2015-01-02 01:08	14487695
<a href="#">north-korea-150101.osm.pbf.md5</a>	2020-04-05 08:23	61
<a href="#">north-korea-160101-free.shp.zip</a>	2018-04-27 03:41	25578613
<a href="#">north-korea-160101-free.shp.zip.md5</a>	2018-05-03 16:31	66
<a href="#">north-korea-160101.osm.pbf</a>	2016-01-02 01:04	15650598
<a href="#">north-korea-160101.osm.pbf.md5</a>	2020-04-05 08:26	61
<a href="#">north-korea-170101-free.shp.zip</a>	2018-04-27 04:00	29122388
<a href="#">north-korea-170101-free.shp.zip.md5</a>	2018-05-03 16:31	66
<a href="#">north-korea-170101.osm.pbf</a>	2017-01-02 01:42	17568984
<a href="#">north-korea-170101.osm.pbf.md5</a>	2020-04-05 08:07	61
<a href="#">north-korea-180101-free.shp.zip</a>	2018-04-27 03:57	42751822
<a href="#">north-korea-180101-free.shp.zip.md5</a>	2018-05-03 16:32	66
<a href="#">north-korea-180101.osm.pbf</a>	2018-01-01 23:43	23759664
<a href="#">north-korea-180101.osm.pbf.md5</a>	2020-04-05 08:20	61




그림 2. 북한 평양시의 OSM 데이터

### ○ OSM 데이터의 한계점

- OSM은 오픈소스 방식의 사용자 참여형으로 데이터가 구축되고 있으며, 이에 따라 데이터 내의 공간객체에 존재하는 몇 가지 한계점이 존재한다.
- 먼저, 건물과 같이 상대적으로 크기가 작고 많은 수가 존재하는 객체들은 일부가 누락되는 문제가 존재한다. 북한 지역에도 마찬가지로 주요 건물 외의 소형 건물 중 다수가 누락되어 빈 토지로 기록되어 있는 것을 확인할 수 있다.
- 또한, 객체의 신뢰성을 확보하기 어렵다는 문제가 존재한다. 객체 누락 여부에 일관성이 없으며, 구축된 객체에 대해서도 자료의 신뢰성이 제공되지 않고 있다.
- 이에 OSM 데이터를 기본공간정보로써 활용하기 위해서는 추가적인 검토 및 데이터 정제 절차가 요구된다.

### ○ 학습데이터셋 구축을 위한 OSM 데이터 정제

- OSM은 영상과 가까운 시기로 매칭되는 레이블 데이터로 활용될 수 있다는 점에서 학습데이터셋으로써 활용가치가 높다. 그러나 전술한 대로 일부 객체의 누락, 최신성 부재 등의 문제가 존재한다. 또한, 고해상도 위성영상의 Off-nadir로 인해 건물과 기존 레이블이 기하적으로 일치하지 않는 문제도 발생할 수 있다(그림 3). 이러한 불일치성은 딥러닝 네트워크 학습에 장애물이 될 수

있으며, 이는 결과적으로 공간정보 추출 성능의 저하로 이어진다. 이에 본 연구에서는 기존 OSM의 누락된 건물을 추가하고 기하적 오차를 제거하는 추가 검토·정제 과정을 수행하였다.



그림 3. OSM과 고해상도 위성영상 비교

- 먼저, 학습에 활용되는 위성영상과 시기가 가장 가까운 OSM 데이터를 확보하였다. 위성영상의 촬영 일자는 2017.04.27.이며, 이와 가장 가까운 시기의 OSM 데이터는 2017.01.01. 데이터이다.
- 확보된 OSM 데이터를 기준으로 누락된 건물을 추가하고, 기하적으로 일치하지 않는 객체들의 위치를 조정하여 OSM 정제를 수행하였으며, 기존 OSM과 그 결과는 그림 4와 같다.



기존 OSM(2017.01.01.)

정제된 OSM 데이터

그림 4. 기존 OSM과 정제된 OSM 데이터


## 나. 고해상도 위성영상 수집

### ○ 네트워크 학습을 위한 고해상도 위성영상 활용

- 현재 운용되고 있는 고해상도 위성영상의 공간해상도는 전정색 (panchromatic) 기준 0.3~0.5m로, 건물, 도로 및 대형 차량까지 육안으로 확인되는 수준이다. 본 연구의 목표 공간정보 항목인 건물/도로 객체의 추출을 위해서 북한 지역에 대한 고해상도 위성영상을 수집하고, 이를 바탕으로 딥러닝 학습데이터셋을 구축하였다.
- 학습을 위한 고해상도 위성영상으로는 GeoEye-1 위성영상을 활용하였다. 활용된 GeoEye-1 위성영상의 구체적인 세부사항은 표 4와 같다. GeoEye-1 위성영상을 네트워크 학습과 평양시 건물 및 도로 추출 기법의 시범 적용에 활용되었다.

표 4. 활용된 GeoEye-1 위성영상의 세부사항

구분	내용
분광밴드	PAN(panchromatic) VNIR(visible and near-infrared)
공간해상도	PAN: 0.46m VNIR: 1.84m
촬영 지역	북한 평양시
촬영 시기	2017년 4월 27일
Off-nadir	30.4°






○ 검증을 위한 Worldview-2 고해상도 위성영상 수집

- GeoEye-1 위성영상으로부터 학습된 딥러닝 네트워크의 이종위성에 대한 적용성을 검증하기 위하여, 본 연구에서는 Worldview-2 고해상도 위성영상을 수집하였다. 수집된 Worldview-2 위성영상은 4장이며, 세부사항은 표 5와 같다.

표 5. 활용된 Worldview-2 위성영상의 세부사항

구분	내용			
분광밴드	PAN(panchromatic) VNIR(visible and near-infrared)			
공간해상도	PAN: 0.46m VNIR: 1.84m			
촬영 지역	북한 평양시			
촬영 시기	2020년 6월 8일	2020년 11월 2일	2021년 2월 2일	2021년 4월 8일
Off-nadir	17.9°	12.4°	9.5°	18.3°



- 공간해상도가 동일한 다시기의 Worldview-2 위성영상을 활용하여 타시기 이종위성에 대한 딥러닝 네트워크의 성능 검증을 수행하였다. 이종위성에 대한 적용성 검증의 정략적 평가를 위해 평양시 일부 지역에 대한 추가적인 검증용 레이블 데이터를 확보하였다(그림 5).



그림 5. Worldview-2 영상 기준 검증용 레이블 데이터

## 다. 패치 기반의 딥러닝 학습데이터셋 구축

### ○ 딥러닝 학습을 위한 패치 기반의 데이터셋

- GeoEye-1 위성영상과 정제된 OSM 데이터는 함께 매칭되어 학습데이터셋으로 활용되었다. 딥러닝 네트워크는 고정된 크기의 입력자료를 요구한다. 이에 매칭된 위성영상 및 레이블 데이터를 네트워크 학습을 위한 패치 형태의 데이터셋으로 재구성하였다.
- 학습데이터셋 구축을 위해 전체 영상을 대상으로 특정 크기의 패치로 전체 영상을 상하좌우로 옮겨가며 자른 뒤, 레이블 데이터와 함께 매칭하여 세트로 구성하였다(그림 6).



그림 6. 패치 형태의 학습데이터셋 구축 방법

- 전체 영상의 크기(화소 수)는 (4092,2797)이며, 본 연구에서 구축된 딥러닝 네트워크의 고정된 입력자료의 크기(화소 수)는 (256,256)이다. 학습데이터셋의 패치 크기(화소 수)를 (512,512)로 설정하여 학습마다 패치 내의 무작위(random)로 일부분이 선택되어 활용되도록 하였다.
- 중복 지역을 설정하여 영상을 잘라 총 96장의 패치 데이터를 구축하였으며, hdf5 파일의 형식으로 별도 저장·구축하였다.

### ○ 학습데이터셋 전처리

- 본 연구에서는 네트워크의 정확도 및 강건성(robustness) 향상을 위해 학습데이터셋에 대하여 전처리를 수행하였다. 먼저, 위성영상마다 존재하는 방사적 스케일(scale)을 균일화해주기 위하여



Min-Max Normalization을 적용하였다. 영상 내에 존재하는 모든 방사값들을 0~1 사이의 값들로 정규화시켜 학습데이터셋을 재구성하였다.

- 학습데이터 양의 부족 및 네트워크의 과적합에 따른 문제를 개선하기 위하여 data augmentation을 수행하였다. data augmentation은 학습데이터셋의 수량 및 다양성을 개선하는 방법론으로, 본 연구에서는 공간적 augmentation(random scaling, flipping, rotating) 및 방사적 augmentation(random brightness, contrast)을 적용하였다. data augmentation의 파라미터는 매번 학습마다 무작위(random)하게 설정되었으며, 학습이 진행됨에 따라 단계적으로 적용하였다.
- 전체 학습데이터셋은 네트워크의 학습(training) 및 시험(testing)을 위해 7:3의 비율로 분할되었다. 시험 데이터셋은 전체 학습과정에서 사용되지 않았다.

## 2. 기본공간정보 추출 딥러닝 네트워크 개발

본 사업에서는 공간정보 자동생성을 위한 딥러닝 네트워크를 개발하였다. 영상 분류에 대표적으로 활용되는 딥러닝 기술인 semantic segmentation 네트워크가 개발되었으며, 개발된 네트워크는 북한 평양시를 대상으로 학습 및 시범 적용되었다. 이종영상에 대한 적용성을 검증하기 위해, Worldview-2 영상을 활용하였으며, 결과를 정량적으로 비교·분석하였다. 이종영상 적용에 따른 분류 성능 저하를 보완하기 위해 추가 학습데이터셋을 구축하여 모델을 개선하였으며 그 결과를 분석하였다.

### 가. 공간정보 자동생성 딥러닝 네트워크 개발

#### ○ 영상 분류를 위한 딥러닝 네트워크

- 영상 분류를 위한 딥러닝 네트워크에는 image classification을 위한 네트워크 구조와 semantic segmentation을 위한 네트워크 구조가 있다(그림 7). image classification 네트워크는 영상 수준(image-level)의 분류를 수행하며, semantic segmentation 네트워크는 화소 수준(pixel-level)의 분류를 수행한다는 차이점이 있다. image classification 네트워크를 활용한 sliding window 기반의 방법론은 연산 상 비효율적이며, 사용할 수 있는 패치 크기의 한계가 있다.

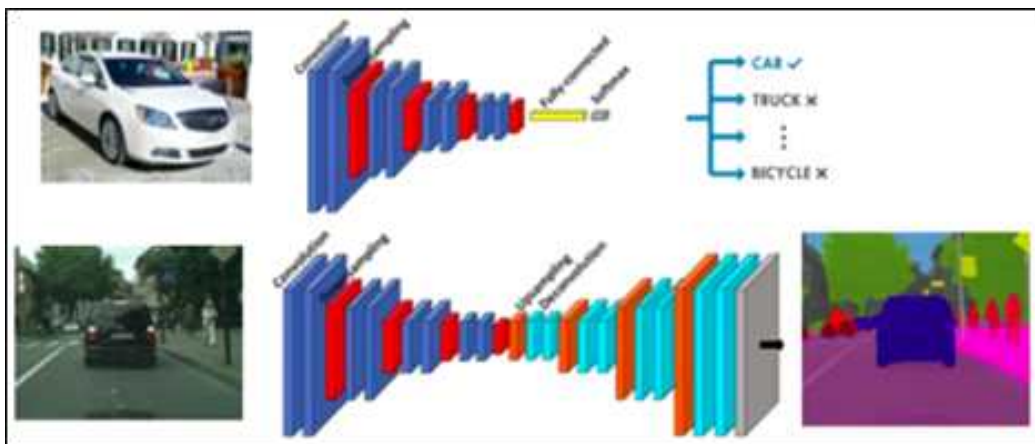


그림 7. Image classification 및 semantic segmentation을 위한 딥러닝 네트워크 구조

- 한편, 입력자료와 출력자료의 크기가 동일하여 바로 화소 수준의 분류를 수행할 수 있는 semantic segmentation 네트워크가 연구되었다. Semantic segmentation 네트워크는 영상이 압축되는 encoder 과정에 다시 원래의 크기를 회복하는 decoder가 이어져 입력자료와 같은 크기의 결과를 출력하는 구조를 지닌다.
- 본 연구에서는 전체 영상 크기가 큰 고해상도 위성영상의 특성을 고려하여, semantic segmentation 방법론을 선정하였다. 본 연구의 semantic segmentation 네트워크는 그림 8과 같이 학습이 이루어진다. 먼저 입력자료로 실제 위성영상이 활용되며, 네트워크는 이러한 입력자료를 받아 이진(binary)의 예측자료로 출력한다. 이러한 과정을 feed-forward라고 부른다. 이후, 출력된 예측자료와 실제 참조자료(reference data, 혹은 labeled data)간 차이를 기반으로 네트워크의 파라미터가 조정된다. 이때 정답과 예측과의 차이를 정의하는 함수를 손실함수라고 부른다. 손실함수를 통해 네트워크의 파라미터를 조정하고 모델을 학습시켜 나가는 과정을 back-propagation이라고 부른다.

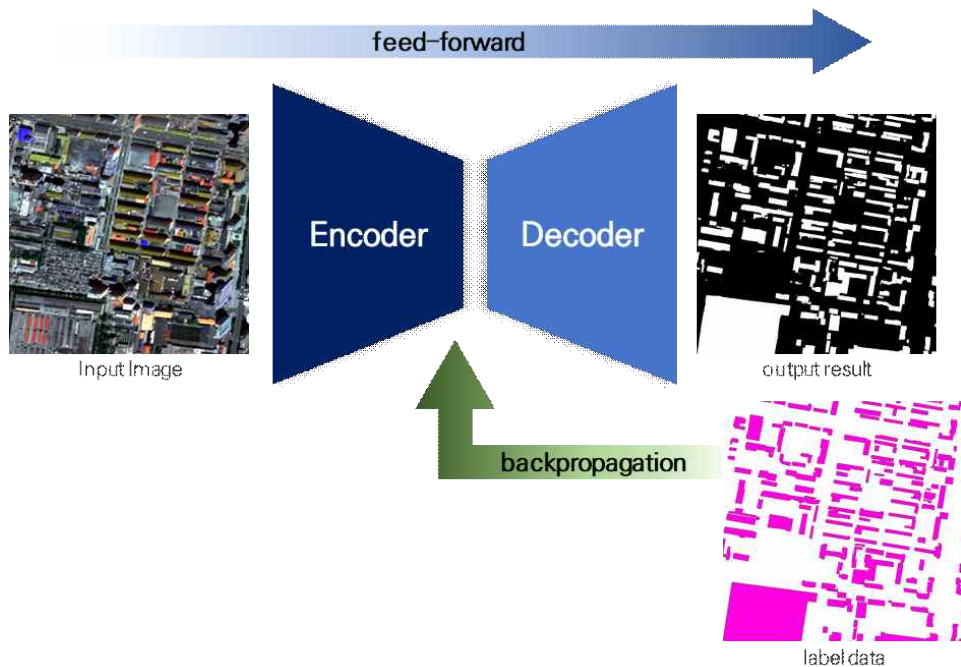


그림 8. 공간정보 추출을 위한 semantic segmentation 네트워크의 학습 과정

○ 네트워크 간 성능 비교를 위한 의미론적 분할 네트워크 선정

- 본 연구에서는 세 가지 semantic segmentation 네트워크를 구축하여 세 가지 구조에 따른 추출 결과를 정량적으로 비교하고, 우수한 결과를 보이는 네트워크를 선정하였다. 사용된 세 가지 네트워크는 U-Net(Ronneberger et al., 2015), LinkNet(Chaurasia et al., 2017), FPN(Feature Pyramid Network; Lin et al., 2017)이다(표 6).

표 6. 세 가지 semantic segmentation 네트워크 구조

네트워크	구조	특징
U-Net		<p>생의학 영상 분류를 위한 처음 제안된 네트워크로, skip-connection을 통해 세밀한 분할 결과를 생성한다.</p>
LinkNet		<p>U-Net과는 다르게 Encoder와 Decoder가 concatenate가 아닌 합(add)으로 연결되어 있다.</p>
FPN		<p>multi-level feature map을 최종 예측 과정에 활용하여 다양한 크기의 객체에 대해 견고한 결과를 보인다.</p>

- 이와 더불어 세 가지 네트워크 모두에 동일하게 미세조정 (fine-tuning)을 적용하였다. fine-tuning은 다량의 학습데이터셋을 구하기 어려운 경우에 사전에 학습된 모델을 가져와 backbone network로 활용하고 파라미터를 추가로 조정해주는 방법론을 말한다. 본 연구에서는 최근 가장 우수한 분류 성능을 보이는 EfficientNet(Tan & Le, 2019)을 backbone network로 활용하여 세 가지 네트워크의 파라미터를 미세조정(fine-tuning)하였다.

○ 모델 학습 파라미터 및 평가지표

- 모델 학습을 위한 손실함수는 Cross Entropy를 사용하였다. Cross Entropy는 다음 식으로 정의된다. 값이 클수록 정답과의 차이가 많은 것을 의미하며, 이를 기반으로 모델은 손실함수를 줄이는 방향으로 학습된다.

$$E = - \sum [y \log(x) + (1 - y) \log(1 - x)]$$

*y* : label  
*x* : prediction

- 본 연구의 구체적인 학습 파라미터 및 실험 환경은 표 7과 같다.

표 7. 학습 파라미터 및 실험 환경

구분	내용
Learning Rate	0.0002 (exponential decay 0.96)
Batch Size	4
Epoch	500
Optimizer	Adam Optimizer
GPU	RTX 2070 Super GPU
CPU	i5-6600 CPU @ 3.30Ghz
Library	python tensorflow-gpu 2.0.0.

- 결과의 정량적 검증을 위한 평가지표는 의미론적 분할에서 가장 널리 활용되는 F1-score와 IoU(mean of Intersection Over Union)가 활용되었다. F1-score와 IoU는 그림 9와 같이 정의된다. 두 지표 모두 0~1 사이 값을 가지며, 값이 클수록 분류 정확도가 높음을 의미한다.

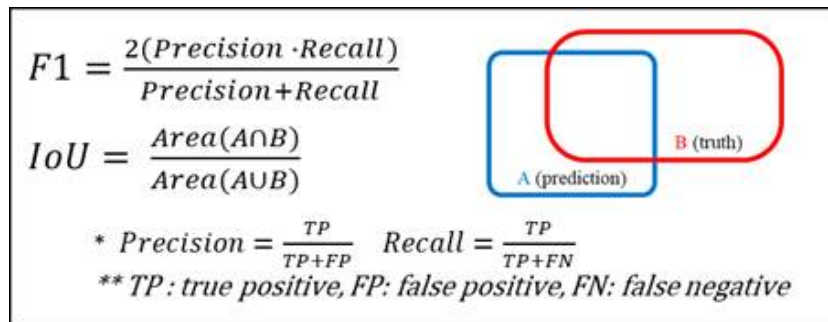


그림 9. 정확도 평가 지표

## 나. 네트워크 시범 적용 및 검증

### ○ GeoEye-1 활용 네트워크 학습 및 시범 적용

- 우선, 본 연구에서는 GeoEye-1 위성영상을 기반으로 구축된 학습데이터셋을 활용하여 세 가지 딥러닝 모델을 학습시켰다. 건물 추출 네트워크의 학습 과정은 그림 10과 같다. 학습이 진행됨에 따라 건물과 도로 객체 모두에 대해서 손실함수가 유의미하게 감소함을 확인할 수 있다.

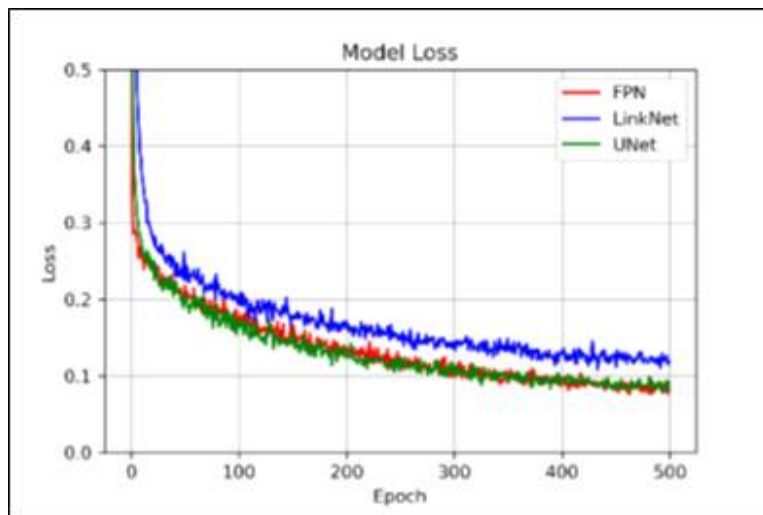


그림 10. 모델 학습 과정 (손실함수)

- 그림 11과 그림 12는 각각 시범 적용 결과와 정답데이터(정제된 OSM)를 보여준다. 각각 green 화소와 red 화소가 건물을 의미한다. 평양시에 존재하는 역, 호텔, 주요 건물과 같은 큰 크기의 건물부터 일반 주택과 같은 비교적 작은 크기의 건물까지 추출됨을 확인할 수 있다. 그러나 특이한 구조 보이는 건물 및 판자촌과 같은 매우 작은 크기의 건물의 경우 모델이 정상적으로 추출하지 못하는 한계점을 발견하였다.





그림 11. GeoEye-1 영상 기준 건물 추출 적용 결과 (FPN 네트워크)



그림 12. 북한 평양시 건물 객체의 정답데이터



- 표 8은 세 가지 네트워크의 결과 간 정량적 비교를 보여준다. 세 가지 네트워크 중 FPN이 가장 높은 건물 추출 정확도를 보였으며, 각각 IoU 0.8017, F1 0.8806의 정확도로 평양시 건물을 추출하였다. 이는 FPN의 multi-level을 고려하는 구조적 특성이 다양한 크기가 존재하는 건물 객체 추출에 유리하게 적용된 것으로 분석된다.

표 8. GeoEye-1 영상 기준 세 가지 네트워크의 분류 정확도 비교

구분	IoU	F1
U-Net	0.7794	0.8641
LinkNet	0.7985	0.8778
FPN	0.8017	0.8806

- 그림 13은 세 가지 네트워크의 건물 추출 결과를 시각적으로 보여준다. 네트워크 간 결과의 시각적 차이는 크지 않은 것을 확인할 수 있다. 세 가지 네트워크의 결과에서 모두 노이즈 형태의 에러가 존재하며, 건물의 경계가 둥글거나 휘어져 비현실적으로 보이는 한계점을 확인할 수 있다.

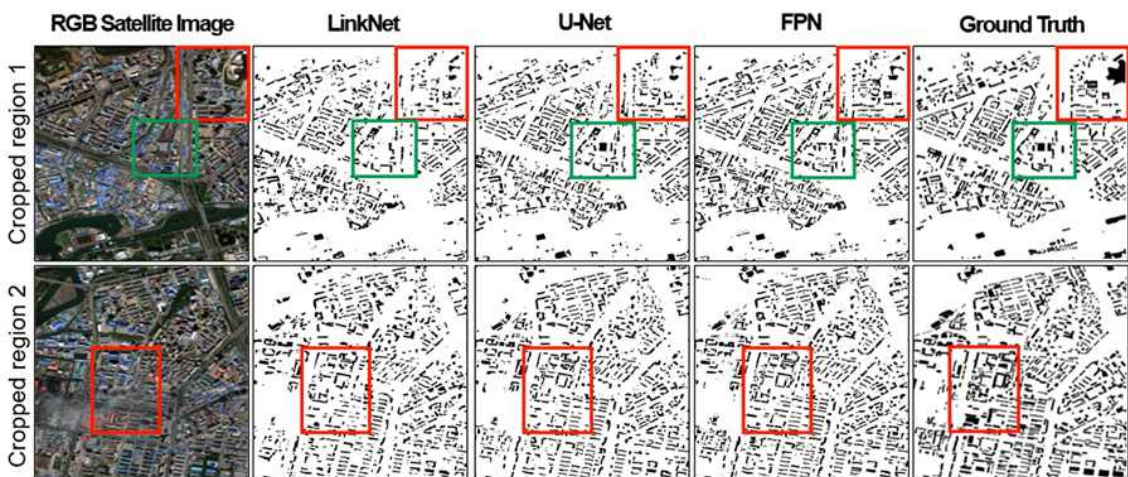


그림 13. 평양시 일부 지역에 대한 세 가지 모델의 건물 추출 결과 비교

○ 학습된 네트워크의 이종영상 적용성 검증

- 일반적으로 학습된 자료와 다른 특성의 새로운 자료에 학습된 모델을 그대로 적용할 경우, 모델 성능의 저하가 발생한다. 본 연구에서는 학습된 네트워크의 이종위성에 대한 적용성을 검증하기 위하여 Worldview-2 영상을 이용하여 건물 추출을 수행하였다.
- 그림 14와 표 9는 Worldview-2 위성영상에 대한 적용 결과를 보여준다. 학습된 네트워크를 다른 시기의 타 위성영상에 적용할 경우, 정확도가 0.7819(F1 기준)로 감소하는 것을 확인할 수 있다. 시각적으로 건물로 확인하기 어려운 노이즈 수준의 에러가 추출되고, 경계가 불분명한 건물이 추출되었다.



그림 14. Worldview-2 영상 기준 건물 추출 결과

표 9. 이종영상 적용성 검증을 위한 정확도 비교

구분	F1
GeoEye-1 검증 결과	0.8806
Worldview-2 적용 결과	0.7819

○ Worldview-2 영상을 활용한 네트워크 개선

- 한 장의 GeoEye-1 영상에 과적합된 네트워크를 개선하기 위해, 본 연구에서는 수집한 Worldview-2 위성을 활용하여 추가 학습

을 수행하였다. 레이블 데이터 구축의 현실적 한계점을 고려하여 기존 GeoEye-1 영상 기준 레이블 데이터를 활용하였다. GeoEye-1 기준 레이블 데이터에서 일부 객체 위치를 조정하여 4장의 Worldview-2 영상에 적용하였으며, 총 128장의 패치를 추가 구성하였다.

- 또한, GeoEye-1 학습데이터 중 건물이 거의 존재하지 않는 패치를 필터링하여 제거하였다. 기존 Min-Max Normalization의 경우, 영상의 방사 끝값 1%를 제거한 뒤 Normalization을 다시 적용하였다.
- 그림 15, 그림 16, 표 10은 개선된 네트워크 결과를 보여준다. 개선된 네트워크를 적용하였을 때, 그 전과 비교하여 F1 기준 약 0.06의 정확도 향상 효과를 확인할 수 있다(표 10). 그림 15 및 그림 16에서 red 화소는 네트워크로부터 추출된 건물을 의미하며, cyan 화소는 실제 건물에서 누락된 부분을 의미한다. GeoEye-1 영상의 결과에서는 강 우측 큰 크기의 건물 외에는 대부분의 건물들이 추출됨을 확인할 수 있다(그림 15).



그림 15. GeoEye-1 영상 기준 개선된 네트워크의 결과






그림 16. Worldview-2 영상 기준 개선된 네트워크의 결과

표 10. 개선된 네트워크의 정확도 비교

구분	모델 개선 전 정확도 (F1)	모델 개선 전 정확도 (F1)	정확도 증감
GeoEye-1 영상 기준 결과	0.8806	<u>0.9479</u>	+ 0.0673
Worldview-2 영상 기준 결과	0.7931	<u>0.8571</u>	+ 0.0640

- Worldview-2 영상의 결과에서는 여전히 누락된 건물 객체들이 남아있었으나, 추출된 건물 객체는 경계가 분명해져 시각적으로 개선된 형태의 객체를 얻을 수 있었다(그림 16). 이는 정량적으로도 확인할 수 있다. 개선된 네트워크 적용에 따라, Worldview-2 위성영상의 건물 추출 결과가 0.7931에서 0.8571로 0.0640(F1 기준) 상승한 것을 확인할 수 있다(표 10).

### 3. 기본공간정보 데이터셋 구축

본 사업에서 개발된 프레임워크를 통해 북한 평양시에 대한 최종 기본공간정보가 생성되었다. 생성된 기본공간정보는 건물, 도로, 식생, 수계를 포함하고 있다. 또한, 본 사업에서는 최종 생성된 기본공간정보의 의미와 한계점을 제시하였으며, 기존 OSM과의 비교·분석을 수행하였다.

#### 가. 대상 지역의 기본공간정보 생성

##### ○ 기본공간정보 항목별 추출 기법 선정

- 본 연구에서 고해상도 위성영상으로부터 추출하는 기본공간정보 항목은 시설물(건물), 교통시설(도로), 수계(하천), 식생이다. 본 연구에서는 각 항목에 적절한 추출 방법론을 구축하였다. 객체의 크기가 상대적으로 작고 분광적 특성이 다양한 건물과 도로 객체(urban feature)는 딥러닝 기반 방법론을 적용하였다.
- 하천과 식생의 경우 객체의 크기가 크고 상대적으로 분광적 특징이 균질(homogeneous)하다. 이에 따라 본 연구에서는 하천과 식생은 밴드 조합(band combination) 방법론을 적용하였다. 식생은 NDVI(Normalized Difference Vegetation Index)를, 하천은 NDWI(Normalized Difference Water Index)를 활용하였다. 각 인덱스는 다음과 같이 정의된다.

$$NDVI = \frac{NIR - Red}{NIR + Red}, \quad NDWI = \frac{Green - NIR}{Green + NIR}$$

$$threshold: NDVI \geq 0.4, \quad NDWI \geq 0.25$$

##### ○ 평양 시 기본공간정보 생성

- 그림 17은 평양시의 최종 기본공간정보 생성 결과를 보여준다. 영상으로 수집된 평양시 중심부를 기준으로 기본공간정보를 생성하였으며, 네 가지 기본공간정보 항목을 추출하였다. 기본공간정보는 좌표정보가 있는 raster 데이터 형식으로 산출된다. 건물 및 도로는 딥러닝 네트워크로부터 추출되며, 형태학적 경계가 명확해 현실적인 형태의 산출물을 얻을 수 있었다.




그림 17. 북한 평양시 기본공간정보 생성 결과

○ 기본공간정보 생성 프레임워크의 한계점과 개선방안

- 본 연구에서 생성된 기본공간정보에는 다음과 같은 한계점이 존재한다. 먼저, 딥러닝 네트워크가 크기가 작은 일부 건물 객체를 누락하는 한계점이 있다. 네트워크 개선을 통해 이종위성에서도 경계가 분명하고 시각적으로 우수한 추출 결과를 얻을 수 있었으나, 모든 건물을 빠짐없이 추출하는 데에는 기술적 한계가 존재하였다. 도로의 경우, 위성의 Off-nadir 및 그림자에 의해 일부가 끊어진 형태로 추출되는 한계점이 존재하였다.
- 위와 같은 한계점에 대해 다음과 같은 개선방안이 존재한다. 먼저 이종영상 적용 시 일부 건물이 누락되는 문제를 해결하기 위해, 다종위성 다시기 영상을 활용하여 추가 학습데이터셋을 구축하고 모델을 개선하는 방안이 존재한다. 활용되는 고해상도 위성 영상의 종류를 보다 다양하게 구축할 뿐만 아니라, 공간해상도가 서로 다른 영상을 학습에 활용하여 보다 강건(robust)한 모델을 구축할 필요가 있다.
- 또한, 영상의 기하정확도 및 Off-nadir에 의해 발생한 에러를 개

선하기 위하여 별도의 기하보정을 적용하거나 정사보정된 영상을 활용하는 방안이 있다. 본 연구에서 활용된 학습데이터셋은  $30.4^\circ$ 의 Off-nadir를 지닌 영상으로 건물이 상당히 기울어진 형태로 촬영된 한계점이 존재한다. 정사영상에 가까운 영상을 활용하여 모델을 개선한다면, 보다 지도데이터에 가까운 공간정보가 추출될 것이다.



## 나. 생성된 기본공간정보와 OpenStreetMap 비교분석

### ○ OSM과의 정성적 비교분석

- 그림 18은 기존 OSM과 추출된 건물 객체를 비교하여 보여준다. green 화소는 기존 OSM을 의미하며, red 화소는 제안된 프레임워크를 통해 추가로 추출된 건물을 의미한다. 가시적으로 확인할 수 있듯이 제안된 딥러닝 프레임워크를 통해 기존 OSM에서 누락되었던 다수의 건물 객체가 추가로 추출됨을 확인할 수 있다. 가장 우측 그림에서는 매우 작은 크기의 판자촌 수준의 건물 객체는 제안된 프레임워크로도 추출되기 어려운 한계점을 보여주고 있다.




그림 18. 기존 OSM과 생성된 기본공간정보 비교

- 제안된 프레임워크는 기존 OSM에서 누락되어 있던 수많은 건물 객체에 대한 정보를 추가로 제공해줄 수 있다. 이러한 특징은 OSM 데이터에 단점인 신속성과 정확성을 보완해줄 수 있다. 또한, 모델 기반의 건물 추출 기법을 활용하면 정량적 결과도 함께 산출되기 때문에, 생성된 기본공간정보의 신뢰성 역시 파악할 수 있다. 이처럼 제안된 프레임워크는 기존 OSM을 보완하여 비접근 지역에 대한 개선된 기본공간정보를 제공할 수 있다는 장점을 지닌다.



#### 4. 연구 결론

본 연구에서는 고해상도 위성영상으로부터 비접근지역인 북한 평양시에 대한 기본공간정보를 추출하는 프레임워크를 구축하였다. 본 프레임워크의 핵심 요소인 딥러닝 네트워크를 개발하고 이를 학습하기 위한 평양시 학습데이터셋을 구축하였다. 이로부터 평양시에 대한 기본공간정보를 추출하였으며, 추출된 결과에 대한 정량적·정성적 평가를 수행하였다. 본 사업의 최종 연구 성과는 그림 19와 같이 요약될 수 있다.

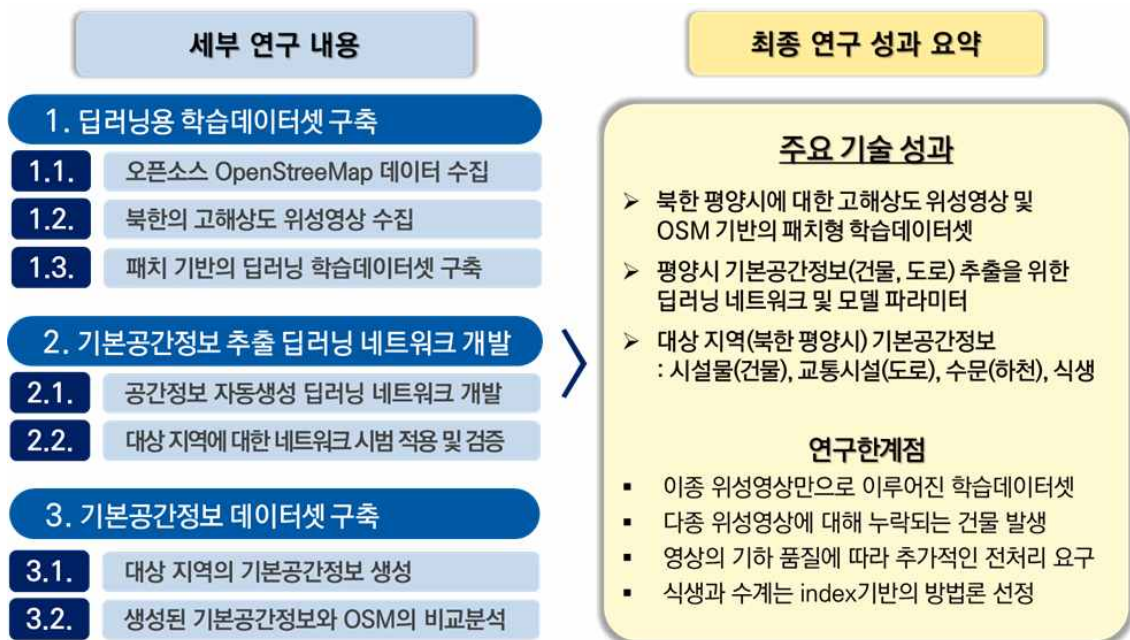


그림 19. 최종 연구 성과 요약

기본공간정보 항목 중 건물과 도로 객체는 딥러닝 네트워크를 통해 추출되었으며, 식생과 하천은 밴드 조합 기법을 통해 추출되었다. 딥러닝 네트워크는 경계가 명확하고 실제와 유사한, 즉 현실적인 형태의 객체를 추출하였다. 다만, 이종위성에 적용 시 입력자료의 특성 차이에 의해 일부 객체들이 누락되는 한계점을 확인하였으며, 현재 수준의 위성영상의 공간해상도 한계로 인해 매우 작은 판자촌 건물들이 추출되지 못한 것을 확인하였다. 또한, 영상이 내포하고 있는 기하적 한계로 인해 지도데이터와 위치 차이가 존재하거나 도로가 끊어지는 문제들이 존재하였다. 한편, 기존 OSM에서 누락되었던 객체들이 제안된 프레임워크

를 통해 다수 추가로 추출됨을 확인할 수 있었다. 이는 기존 OSM이 가지고 있던 정확성, 신속성, 신뢰성을 보완할 수 있다는 것을 의미한다.

본 연구에서 제안된 프레임워크는 북한과 같은 물리적 접근이 어려운 지역에 대한 기본공간정보를 자동생성해줄 수 있다. 비록 정확도 및 강건성 측면에서 전술한 바와 같은 한계점들이 존재하나, 제안된 프레임워크는 북한 지역에 대한 기본공간정보를 위성영상만을 활용하여 효율적으로 제공할 수 있다는 장점을 지닌다. 본 연구에서 구축된 프레임워크는 북한지역의 공간정보 생산체계의 효율성과 신속성을 향상시킬 수 있을 것으로 기대한다. 또한, 본 연구를 통해 구축된 학습데이터셋과 딥러닝 네트워크 기반 프레임워크는 향후 관련 연구의 기반자료로써 활용될 수 있으며, 공간정보 구축을 위한 AI 기술 발전에 기여할 것으로 기대된다.

### III. 사업 성과 및 예산

#### 1. 사업 성과

본 사업의 주요 성과물은 기본공간정보 추출 프레임워크이며, 이는 고해상도 위성영상을 통해 생성한 학습데이터셋과 딥러닝 네트워크로 구성된다. 그 외 본 사업을 통해 아래와 같은 성과가 도출되었다(표 11).

- **기본공간정보 생성을 위한 학습데이터셋**
  - OSM 및 고해상도 영상을 이용한 패치형 학습용 DB
  - 96장의 GeoEye-1 위성영상 기준 학습용 DB와 128장의 Worldview-2 위성영상 기준 추가 학습용 DB로 이루어져 있음
  
- **대상 지역에서 추출한 기본공간정보**
  - 제안된 프레임워크를 통해 구축된 북한 평양시의 기본공간정보 DB
  - 건물, 도로, 수계, 식생, 네 가지 항목들로 구성
  - 각 항목들에 대한 이진(binary) 자료 형태의 래스터 자료
  - 좌표정보 포함
  
- **기본공간정보 생성 기술**
  - 기본공간정보 생성을 위한 딥러닝 네트워크 코드 및 파라미터
  - python tensorflow를 기반으로 구축된 코드
  - 학습이 완료된 모델 파라미터도 포함
  
- **학술발표 2건**
  - 2021 International Symposium on Remote Sensing, 2021년 5월 26일~28일 (온라인 학술대회), 논문 제목: Mapping Inaccessible Areas Using Deep Learning based Semantic Segmentation of VHR Satellite Images with OpenStreetMap Data.
  - 대한원격탐사학회 2021 추계학술대회, 2021년 10월 20일~22일 (온라인 학술대회), 논문 제목: 고해상도 위성영상을 활용한 북한

평양시의 딥러닝 모델 기반 건물 의미론적 분할.

• 인력 양성

- 참여연구원 곽태홍 석사학위 취득 (2021년 8월)

표 11. 본 사업의 예상 성과물 요약

구분	항목	계획	실제 성과
인프라 분야	딥러닝 프레임워크	기본공간정보 생성을 위한 학습데이터셋	OSM 및 고해상도 영상을 이용한 패치형 학습용 DB
		대상 지역에서 추출한 기본공간정보	대상 지역의 기본공간정보 DB (건물, 도로, 식생, 수계)
기술 분야	기본공간정보 생성 기술	북한지역 기본공간정보 추출을 위한 딥러닝 모델	파이썬 기반의 semantic segmenation 네트워크 코드 및 모델 파라미터
	등재지 및 학술발표	1건 이상	학술발표 2건 2021 International Symposium on Remote Sensing 대한원격탐사학회 2021 추계학술대회
	인력 양성	석사학위 1명	참여연구원 곽태홍 석사학위 취득 (2021년 8월)

			
<p>학습데이터셋</p>	<p>기본공간정보</p>	<p>학술발표 2건</p>	<p>석사학위</p>





## 참고문헌

국토교통부(2018a). 2018년 국가공간정보 표준화 연구 - 기본공간정보 데이터셋 표준 모델 개발.

국토교통부(2018b). 2018년도 국가공간정보정책 시행계획.

국토교통부(2018c). 2018년 접근불능지역 공간정보 통합체계 추진방안 연구.

국토교통부(2018d). 제 6차 국가공간정보정책 기본계획.

국토교통부(2021). 2021년도 국가공간정보정책 시행계획.

국토연구원(2007). Establishment of National GIS of Korea. KRIHS SPECIAL REPORT 8.

국토연구원(2017). 통일대비 북한지역 국토이용 모니터링 및 활용방안 연구. 17-21.

국토지리정보원(2012). 국가기본도 선진화방안 연구.

국토지리정보원(2019). 기본공간정보 표준화 및 발전방향 수립 연구.

김미숙 등(2018). 북한 도시·지역 정보화 전략 연구. 한국토지주택공사 토지주택연구원.

박흥기. (2009). 접근불능지역 공간정보 구축방안에 관한 연구. 한국측량학회지. 27(6). 749-760.

Chaurasia, A., & Culurciello, E. (2017, December). Linknet: Exploiting encoder representations for efficient semantic segmentation. In 2017 IEEE Visual Communications and Image Processing (VCIP), 1-4.

Gao, X., Sun, X., Zhang, Y., Yan, M., Xu, G., Sun, H., ... & Fu, K. (2018). An end-to-end neural network for road extraction from remote sensing imagery by multiple feature pyramid network. *IEEE Access*, 6, 39401-39414.

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778.

Li, W., He, C., Fang, J., Zheng, J., Fu, H., & Yu, L. (2019). Semantic segmentation-based building footprint extraction using very high-resolution satellite images and multi-source GIS data. *Remote Sensing*, 11(4), 403.

Lin, T. Y., Dollar, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017). Feature pyramid networks for object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2117-2125.

Neupane, B., Horanont, T., & Aryal, J. (2021). Deep Learning-Based Semantic Segmentation of Urban Features in Satellite Images: A Review and Meta-Analysis. *Remote Sensing*, 13(4), 808.

Ronneberger, O., Fischer, P., & Brox, T. (2015, October). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (pp. 234-241). Springer, Cham.

Sun, W., & Wang, R. (2018). Fully convolutional networks for semantic segmentation of very high resolution remotely sensed images combined with DSM. *IEEE Geoscience and Remote Sensing Letters*, 15(3), 474-478.

Tan, M., & Le, Q. (2019). Efficientnet: Rethinking model scaling for



convolutional neural networks. In International Conference on Machine Learning (pp. 6105-6114). PMLR.

Wu, M., Zhang, C., Liu, J., Zhou, L., & Li, X. (2019). Towards accurate high resolution satellite image semantic segmentation. *IEEE Access*, 7, 55609-55619.

Yakubovskiy, P. (2019) Segmentation Models. Github repository.