


국토위성센터 연구보고서

2021. 12

2021. 12



(우)16517 경기도 수원시 영통구 월드컵로 92(원천동)
TEL 031) 210-2700 FAX 031) 210-2644



국토위성센터 연구보고서

2021.12

국토지리정보원

김혜원	국토위성센터	센 터 장
양효진	국토위성센터	시설연구관
김병희	국토위성센터	시설연구사
신문승	국토위성센터	시설연구사
윤혜원	국토위성센터	시설연구사
이미희	국토위성센터	시설연구사
홍단비	국토위성센터	시설연구사
황정인	국토위성센터	시설연구사

제1장 국토위성기반 정밀영상생산시스템 품질 분석	3
제2장 고해상도 광학위성 복사(대기)보정 기술현황 조사	17
제3장 이종 위성영상 융합 활용을 위한 교차검보정 기초 연구	35
제4장 광학위성영상 구름 인덱스 맵 시범제작	55
제5장 위성영상 사용 편의성 제고를 위한 그림자 추출 알고리즘 성능 비교	71
제6장 고해상도 위성영상 기반 식생지수 산출 시범 적용 실험	85
제7장 국토위성 기반 주제도(지표, 지형)시범제작 및 기술 리뷰	107
제8장 영상분석 기술을 활용한 재난 분석	123
제9장 빅데이터 기반 대용량 위성영상 처리 및 서비스 제공 기초 기술 조사	153
제10장 딥러닝 기반 건물 객체탐지 기초기술 개발	173
제11장 고해상도 위성영상 기반 도로객체 추출을 위한 AI기술 접목 가능성 연구	205
제12장 후속위성 개발 환경 분석을 위한 정책 및 기술동향 조사	225

Ⅰ 표 목차 Ⅰ

<표 1-1> 실험에 사용한 H/W 자원	7
<표 1-2> 모의영상 기반 위치정확도 분석 결과	9
<표 2-1> 복사전달모델 기반의 절대 대기보정	21
<표 2-2> ACIX 대기보정 프로세스 리스트 및 참가자(소속)	24
<표 2-3> ACIX II Land 대기보정 프로세스 리스트 및 참가자(소속)	25
<표 2-4> Landsat-8 Band 4에서의 ATCOR, FORCE, iCOR, LaSRC의 APU값	26
<표 3-1> 기존 밴드 구성과 HLS 산출물 밴드 구성 비교	37
<표 3-2> HLS 프로젝트 산출물 QA밴드 구성 클래스	38
<표 3-3> 밴드 대역폭 조정을 위한 Sentinel-2A/B 계수	40
<표 3-4> 차세대중형위성군 제원 비교(국토위성, 농림위성)	41
<표 3-5> KOMPSAT 기반 교차검보정 및 타 센서와의 접목 사례 관련 문헌	47
<표 5-1> 그림자 탐지 알고리즘	73
<표 5-2> 알고리즘 별 그림자 탐지 성능 결과	77
<표 5-3> 국토위성 적용 결과	80
<표 6-1> 선정된 식생지수	86
<표 6-2> 시계열 식생지수 특성 분석을 위해 사용한 자료	88
<표 6-3> 옥상녹화 추출 가능성 분석을 위해 사용한 자료	90
<표 6-4> 벼의 농작업일정	93
<표 6-5> 산림지역에 대한 식생지수 상관관계	98
<표 6-6> 논 지역에 대한 식생지수 상관관계	99
<표 6-7> 식생지수별 정확도평가 결과	100
<표 7-1> 국토위성 스테레오 영상 정보	115
<표 7-2> CAS500 DTM 및 NGII DEM 정보	115
<표 8-1> 시범적용 재난 및 연구대상 선정기준	124
<표 8-2> 수집 영상 정보	125
<표 8-3> 경상북도 안동시 산불발생 지역	127
<표 8-4> NDVI 기반 안동시 산불 피해범위 탐지 결과	128
<표 8-5> NBR 기반 안동시 산불 피해강도 탐지 결과	129
<표 8-6> 강원도 고성군 산불발생 지역	130
<표 8-7> NDVI 기반 고성군 산불 피해범위 탐지 결과	131

<표 8-8> NBR 기반 고성산불 피해강도 탐지 결과	131
<표 8-9> 강원도 고성군 산불발생 지역	132
<표 8-10> NDVI 기반 울주군 산불 피해범위 탐지 결과	133
<표 8-11> NBR 기반 고성산불 피해강도 탐지 결과	133
<표 8-12> 과거 침수피해 탐지를 위한 수집 영상 정보	134
<표 8-13> 위성 영상 제원	135
<표 8-14> 광학영상 NDWI 기반 피해 범위 탐지	138
<표 8-15> NDWI 결과와 수치지형도 중첩	138
<표 8-16> SAR 기반 피해 범위 탐지	139
<표 8-17> 광학영상 NDWI 기반 피해 범위 탐지	140
<표 8-18> 2018 콩레이 피해 : 영상 기반 피해 범위 탐지	141
<표 8-19> 2018년 집중호우 피해 : 영상 기반 피해 범위 탐지	141
<표 8-20> 대설 피해 탐지를 위한 수집 영상 정보	144
<표 8-21> 광학영상(Landsat-8) 기반 적설지역 탐지	145
<표 8-22> 지수산출 및 무감독 분류 방법을 적용한 적설 지역 탐지	145
<표 8-23> 무감독 분류 결과, 적설지역 클래스	146
<표 8-24> Landsat-8 QA밴드 및 합성영상	146
<표 8-25> 광학영상(Sentinel-2) 기반 적설지역 탐지	147
<표 8-26> 2021년 적설 지역 탐지	147
<표 10-1> 선행연구 적용 알고리즘 분석 결과	178
<표 10-2> 정확도 평가 결과	188
<표 10-3> 유사 연구와 정확도 평가 결과 비교	188
<표 10-4> 이중센서 및 단일센서 데이터의 건물 추출 정확도 분석 결과	189
<표 11-1> U-Net 도로객체 추출 테스트 결과	212
<표 12-1> WorldView, Pleiades, Resurs-P 위성 비교	231
<표 12-2> Gokturk-1A, GaoFen-7, ALOS-3, CartoSat-3 위성 비교	233
<표 12-3> DMC-3, SuperView, ASNARO-1, WorldView-Legion 위성 비교 ..	235
<표 12-4> TerraSAR-X, RADARSAT Constellation, CGS 위성 비교	237

Ⅰ 그림 목차 Ⅰ

<그림 1-1> 정밀영상생산시스템 처리 과정	4
<그림 1-2> 사용한 모의영상 목록 및 위치	6
<그림 1-3> 검사점 취득 방법	6
<그림 2-1> 사용자 친화형 영상 제품 서비스 전/후 사용자 편의성 차이	17
<그림 2-2> MODTRAN을 이용해 계산된 파장별 (좌) 투과도, (우) 복사휘도	20
<그림 2-3> (좌)동일 입력조건에서 MODTRAN과 6S의 복사휘도 결과 비교, (우) 1.9-2.5 μ m 확대	20
<그림 2-4> Komsat-3A 영상 (a) 대기보정 전, (b) 대기보정 후	23
<그림 2-5> Landsat-8 Band 4에서의 ATCOR, FORCE, iCOR, LaSRC의 표면반 사율 비교결과(예시)	26
<그림 2-6> 지상관측자료(실선)와 대기보정모델 적용 결과(점) 예시	27
<그림 2-7> 센서로부터 지표면 물리값으로 보정과정	28
<그림 3-1> Landsat 7호, 8호 밴드와 Sentinel-2 밴드 대역 비교	36
<그림 3-2> HLS프로젝트 영상 처리 과정	37
<그림 3-3> HLS프로젝트 타일링 시스템	39
<그림 3-4> HCC프로젝트 구상도(안)	50
<그림 4-1> 연구 흐름도 및 데이터(KOMPSAT-3, 2019.10.19. 촬영)	56
<그림 4-2> Zhong et al.(2017)의 구름탐지 알고리즘 및 탐지결과 예시	57
<그림 4-3> KOMPSAT-3의 spectral response(Yeom et al., 2018)	58
<그림 4-4> GF-1&HJ-1과 Landsat ETM+의 spectral response 비교	58
<그림 4-5> Landsat 8 적용 결과	59
<그림 4-6> cloud with high confidence map(KOMPSAT-3 적용 결과)	59
<그림 4-7> SVM 결과 제작된 구름 확률도[0,1]	61
<그림 4-8> SVM 결과 제작된 구름 확률도[0,1]	61
<그림 4-9> SVM 결과 제작된 구름 확률도[0,1]	62
<그림 4-10> (좌) KOMPSAT-3(밀양, 2018.10.18. 촬영), (우) 확률도	63
<그림 4-11> (좌) KOMPSAT-3(밀양, 2018.10.18. 촬영), (우) 확률도	63
<그림 4-12> (좌) KOMPSAT-3(밀양, 2018.10.18. 촬영), (우) 확률도	63

<그림 4-13> Landsat OLI QA band 속성 값	64
<그림 4-14> (a)Landsat OLI 영상 일부, (b)SVM 결과 확률도 (c)Landsat QA band (d) QA band 일부 확대	65
<그림 5-1> 그림자 정의(Zhang 등, 2014)	72
<그림 5-2> 그림자 추출에 사용된 Kompsat-3A 영상('18.2.14)	74
<그림 5-3> 건물그림자 추출 관심영역 및 성능 평가 영역(빨간색 박스)	75
<그림 5-4> (a) 수동 추출 결과(노란색 영역), (b) 이진화 결과	76
<그림 5-5> (a) 알고리즘 적용 결과, (b) 이진화 결과	78
<그림 5-6> 2021년 10월 24일 촬영된 국토위성 영상 일부(경기 수원시)	79
<그림 6-1> 시계열 식생지수 특성 분석을 위한 연구지역	87
<그림 6-2> 연구 흐름도	89
<그림 6-3> 옥상녹화 추출 가능성 분석을 위한 연구지역	90
<그림 6-4> 옥상녹화 추출 가능성 분석을 위한 연구흐름도	91
<그림 6-5> 오차행렬	92
<그림 6-6> 연구지역별 NDVI 시계열 변화	93
<그림 6-7> 연구지역별 NDVI 공간적 분포(3월~11월) (계속)	94
<그림 6-7> 연구지역별 NDVI 공간적 분포(3월~11월)	95
<그림 6-8> 연구지역별 식생지수 시계열 변화; (a)산림, (b) 논, (c)인조잔디	97
<그림 6-9> (a), (c) 식생지수 적용 및 (b), (d) 이진화 결과	101
<그림 7-1> 위성영상 기반 농경지 분류 결과	108
<그림 7-2> 위성영상 기반 도심지 분류 결과 (a)건물, 나지 (b)임지 (c)도로 ...	109
<그림 7-3> (a)기존 분류 결과 (b)대기보정 후 분류 결과 (c)토지피복지도	110
<그림 7-4> DSM/DTM 제작 과정(Perko, 2019)	110
<그림 7-5> 스테레오 기하 구성(Jeong and Kim, 2016)	111
<그림 7-6> 촬영각에 따른 정확도(Jeong and Kim(2016))	112
<그림 7-7> DSM의 하천 표현 오류로 인한 DTM 오류	116
<그림 7-8> 경사도 및 사면향도 예시	117
<그림 8-1> 봄·가을철 산불 피해 탐지 흐름도	126
<그림 8-2> Δ NBR 피해등급 분류	128

<그림 8-3> 여름철 침수 피해 탐지 흐름도	135
<그림 8-4> GRDH 원시 영상	137
<그림 8-5> 전처리 완료 영상	137
<그림 8-6> 태풍 하이선 침수피해 분석 결과	139
<그림 8-7> (위) 영상 및 공간정보 중첩 비교 (아래) 피해 현장 사진	142
<그림 8-8> 산사태 지역 시계열 영상	143
<그림 8-9> 드론영상 기반 DSM 제작 및 건물중첩	143
<그림 8-10> 겨울철 적설지역 탐지 흐름도	144
<그림 9-1> HDF 파일 형식	154
<그림 9-2> 데이터 셋(Dataset) 구성 상세	155
<그림 9-3> 데이터 저장 layout 성능 향상 옵션	155
<그림 9-4> 천리안위성 사용자 맞춤형 영상처리 도구	156
<그림 9-5> TIFF 파일 구조	157
<그림 9-6> GeoKeyDirectory 구조	157
<그림 9-7> 데이터 구조 분류 체계	158
<그림 9-8> 관계형 DBMS(MySQL)과 SciDB 데이터 처리 시간 비교 분석	160
<그림 9-9> SciDB에 데이터를 로딩하기 위한 과정	160
<그림 9-10> SciDB 로딩 방법 예시(한국과학기술정보연구원, 2015)	161
<그림 9-11> SciDB에 적용된 in-situ 분석 과정	162
<그림 9-12> SciDB 구조	162
<그림 9-13> SciDB의 데이터 로딩과정	163
<그림 9-14> TuPiX 기반 대용량 고해상도 위성데이터 처리	164
<그림 9-15> KARI 빅데이터 처리 및 분석시스템 구성도	165
<그림 9-16> 검색주문관리 시스템 데이터 처리 흐름도	166
<그림 9-17> 배포관리 시스템 데이터 처리 흐름도	167
<그림 9-18> 국토정보플랫폼 국토위성 검색 화면	167
<그림 9-19> 위성영상 가시화 흐름도(예시)	168
<그림 9-20> AQL 기반 SciDB 가공(예시)	168
<그림 9-21> 위성영상 시각화방법 비교 흐름도	168

<그림 9-22> 각 레벨별 이미지 타일 구성)	169
<그림 10-1> 연구수행 절차	176
<그림 10-2> 국토위성 촬영영상 건물 추출 결과(37713017 도엽)	177
<그림 10-3> CNN 알고리즘 구조	178
<그림 10-4> FCN(좌), U-Net(우) 알고리즘 구조	179
<그림 10-5> SegNet 알고리즘 구조	180
<그림 10-6> Massacchusetts Data Set(좌 : 원영상, 우 : Label)	182
<그림 10-7> U-Net 알고리즘 구조	183
<그림 10-8> U-Net 트레이닝 및 검증 결과	184
<그림 10-9> U-Net 트레이닝 결과 비교	184
<그림 10-10> U-Net 기반 건물탐지를 위한 데이터 구축	185
<그림 10-11> 이종 센서 영상의 U-Net 트레이닝 및 검증 결과	186
<그림 10-12> 각 Data 별 건물탐지 결과	187
<그림 11-1> 공간객체추출 SW 이용 AI 기반 도로객체추출 테스트 결과	205
<그림 11-2> 도로탐지를 위한 항공사진 및 레이블링 데이터 셋(Mnih, 2013)	207
<그림 11-3> U-Net의 구조(Ronneberger, 2015)	210
<그림 11-4> U-Net 학습 결과 Loss 값 분포	211

제1장

국토위성기반 정밀영상생산시스템 품질 분석

1. 배경 및 목적
2. 주요 내용
3. 실험 결과
4. 결론

1. 배경 및 목적

국토위성(차세대중형위성 1호)은 21년 3월 22일 발사에 성공한 후, 약 7개월의 검보정(Calibration/Validation) 기간을 통해 위성 본체 및 탑재체에 대한 점검을 완료하였다. 10월 18일부터 정상 운영 모드에 진입함에 따라, 국토위성센터는 국토위성 지상국 시스템을 기반으로 정밀보정된 정사영상(이하 위성정사영상)을 기본 산출물로 생산 중에 있다.

국토위성 지상국 시스템은 국토위성 영상의 효율적인 수집, 처리, 저장, 관리, 활용을 위해 18년 6월부터 20년 12월까지 개발되었으며, 이후 위성의 정상 운영시점까지 시스템에 대한 검증이 수행되었다. 국토위성 지상국 시스템의 핵심 기술은 위성정사영상의 자동 생산이며, 이를 정밀영상생산시스템(Precise Image Processing System)이라고 부른다. 정밀영상생산시스템은 운영자의 개입을 최소한으로 하여 입력된 기본영상으로부터 정밀 기하보정 및 정사보정이 수행된 위성정사영상을 생산하고, 이를 위해 한반도 전역에 고르게 분포한 지상기준점 영상 칩(GCP Chip)과 고정밀 수치표고모델(DEM)을 사용한다.

본 연구에서는 위성정사영상을 자동 생산하는 정밀영상생산시스템을 간략하게 소개하고, 모의영상(다목적실용위성 3호 및 3A호)과 약 2개월간 운영된 국토위성영상을 기반으로 정밀영상생산시스템의 성능을 평가한 결과를 요약하여 공유한다. 이를 통해 국토위성센터의 기본 산출물인 위성정사영상의 품질을 확인하고, 현 시스템의 한계 및 문제점을 기반으로 개선사항을 도출하고자 한다.

2. 주요 내용

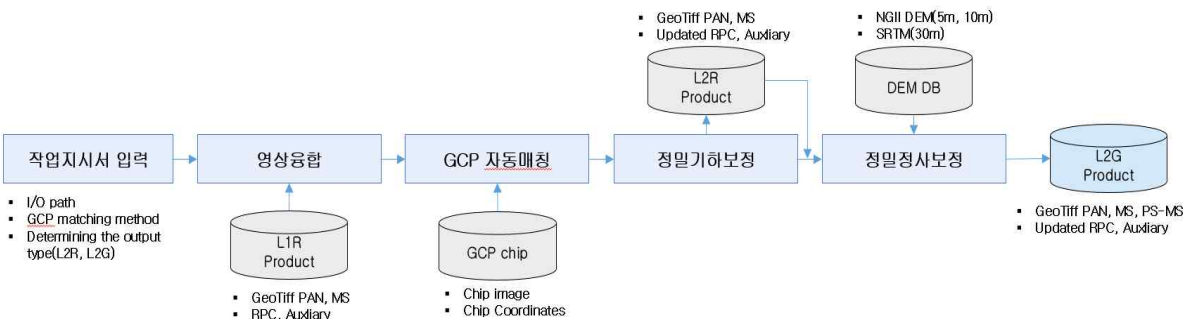
가. 정밀영상생산시스템 성능 평가 방법

정밀영상생산시스템은 기본영상(Level 1R)을 입력받아 정밀 기하보정 영상(Level 2R)과 정밀정사영상(Level 2G)으로 생산한다. 정밀정사영상 생산 과정은 다음 그림 1-1과 같다. 자세한 처리과정 및 알고리즘은 은 박형준 외(2020)에 제시되어 있으며, 본 연구에서는 각 단계에 대해서 간략하게 요약한다.

정밀영상생산시스템은 작업지시서를 통해 영상처리에 필요한 기본적인 요소를 입력받고, 영상융합, GCP Chip 자동매칭, 정밀 기하보정, 정밀 정사보정의 과정을 거쳐 최종적으로 위성정사영

상을 처리·저장한다. 영상융합은 Pan-sharpening 알고리즘을 통해 저해상도 다중분광 영상과 고해상도 전정색 영상의 상관관계를 기반으로 고해상도 다중분광 영상을 제작하는 것이다. 영상융합을 통해 GCP Chip과 위성영상의 영상정합 성능을 높일 수 있다는 실험결과를 바탕으로 GCP Chip 자동매칭 이전에 수행된다(신정일 외, 2018). GCP Chip 자동매칭을 위해서는 GCP Chip 데이터베이스를 사용하는데, GCP Chip이란 정밀 관측된 지상좌표를 영상의 중심좌표로 해서 영상을 일정 크기의 chip 형태로 가공한 것을 말한다. 정밀영상생산시스템을 위해서 남한, 북한에 각각 약 25,000점의 GCP Chip 데이터베이스를 구축하였다. 남한의 GCP Chip은 항공영상과 통합 기준점, 삼각기준점 및 사진기준점을 사용하였으며, 북한의 Chip은 위성영상과 국방부 기준점 및 사진기준점 등을 사용하여 제작하였다. GCP 자동매칭은 먼저 위성영상의 초기 센서모델을 기반으로 위성영상 내 포함된 GCP Chip을 추출하고, 추출된 GCP Chip의 기하를 위성영상의 영상좌표로 투영하여 위성영상과 기하를 일치시킨다. 이후 4단계의 피라미드 영상을 생성하여 위성영상과 GCP Chip의 정합점을 추출하고, RFM 기반의 RANSAC을 이용하여 오정합점을 제거하여 최종 GCP Chip을 추출한다.

정밀기하보정은 초기 RFM에 보정 계수를 추가하는 방법으로 수행되며, 보정 모델로는 Affine Model의 1차 다항식을 사용한다. RFM을 보정하는 방식은 RPC를 직접 갱신하는 방법 대비 정밀 센서모델링에 필요한 GCP의 수량이 적다는 장점이 있다. 정밀기하보정이 완료된 영상의 기복변위를 제거하기 위해 DEM을 이용하여 정밀정사보정을 수행한다. 이를 위해 정밀보정영상의 격자를 지도좌표계상의 정규격자로 변환하여 정밀정사영상의 격자를 생성하고, DEM 및 지오이드를 사용하여 높이값을 보간 한 정밀보정영상의 화소값을 정밀정사영상 격자에 입력하여 정밀정사영상(위성정사영상)을 생산하게 된다.



<그림 1-1> 정밀영상생산시스템 처리 과정


정밀영상생산시스템의 성능 평가는 자동처리 성능 및 위치정확도 평가로 구분하였다. 본 시스템은 사용자의 개입이 최소화되도록 개발되었으므로, 결과물이 생산되는데 소요되는 시간을 확인하고 실제 자동처리 성공률 및 실패 원인을 확인하였다. 또한, 정밀영상생산시스템의 최종 산출물이자 국토위성센터의 기본 산출물인 위성정사영상의 품질을 평가하기 위해 위치정확도를 평가하였다. 위성정사영상의 위치정확도는 위성정사영상 생성에 사용되는 많은 GCP Chip과 타 영상을 기반으로 구축된 수치지형도와와의 비교를 통해 분석하였다. 위성정사영상과 해당지역의 1/5,000 수치지형도를 중첩하고, 각 도엽에서 4점을 추출하고 대응하는 위성정사영상에서의 위치를 확인하여 차이를 산정하였다.

나. 연구 자료

정밀영상생산시스템의 성능 검증을 위해서 모의영상(다목적실용위성 3호 및 3A호)과 국토위성영상을 사용하였다. 모의영상은 정밀영상생산시스템 개발을 위해 한국항공우주연구원으로부터 제공 받았으며, 총 158장의 영상 중 남한지역은 109장(접경 24장 포함), 북한지역 49장으로 구성되어 있다. 자동처리 성능 평가를 위해서는 158장을 모두 사용하였으며, 위치정확도 평가를 위해서는 그 중 10장을 사용하였다. 그림 1-2는 본 연구에서 위치정확도 평가에 사용한 모의영상의 목록과 위치를 나타내며, 그림 1-3은 앞서 연구 방법에서 간략하게 설명한 검사점의 취득 방법을 묘사한 것이다.

국토위성영상은 국토위성의 정상 운영이 시작된 21년 10월 18일부터 12월 8일까지 한반도를 촬영한 634장을 대상으로 자동처리 성능 평가를 수행하였으며, 이중 10장을 이용하여 위치정확도 평가를 수행하였다. 모의영상의 경우 기 촬영된 영상을 사용하였기 때문에 촬영기하 등 위치정확도 분석에 있어서 고려되어야 하는 요소 등에 대한 다양한 평가에 어려움이 있었다. 국토위성영상의 경우에는 촬영기하에 따른 영향을 분석하기 위해서 동일지역에서 여러 차례 촬영한 영상을 적극 활용하였다. 북한지역의 경우 평양과 청진을 촬영한 영상을 활용하였으며, 청진의 경우 Roll 및 Pitch 기동 등에 변화를 두어 촬영하고 그에 따른 정확도를 확인하였다. 남한의 경우에는 서울, 순창을 촬영한 영상을 활용하였고, 서울은 Roll 기동 영상을 사용하였고 순창의 경우 직하로 촬영된 영상을 사용하였다. 서울 영상의 경우에는 국토위성뿐만 아니라 기존에 모의영상으로 촬영한 영상이 있어, 동일한 보정을 수행한 결과를 상호 비교할 수 있었다. 그림 1-4는 본 연구에서 사용한 국토위성영상과 1/5,000 수치지형도를 중첩한 모습을 예시로 나타낸다.

Product ID	Area
C1_20190120043558_21100_00056047_L1R	Pyongyang
C1_20190223045415_21614_00066626_L1R	Sinuiju
C1_20181102041548_19906_00147222_L1R	Wonsan
C1_20200508041443_28263_00041150_L1R	Kangwon
C1_20151229044555_04205_00003616_L1R	Paju
C1_20151211044753_03933_00020757_L1R	Seoul
C1_20180127044122_15690_00040490_L1R	Incheon
C1_20190324042830_22052_00188346_L1R	Jeonnam
C1_20170303045122_10703_00054714_L1R	Jeju
C1_20160530044124_06517_00023477_L1R	Chungnam





L2G (standard)	GCP chip	Digital topographic maps



<그림 1-2> 사용한 모의영상 목록 및 위치

<그림 1-3> 검사점 취득 방법



<그림 1-4> 국토위성영상과 1/5,000 수치지형도를 중첩한 모습
(좌) 21.10.21 촬영 - 청진 (우) 21.10.26 촬영 - 서울

3. 실험 결과

가. 정밀영상생산시스템 자동처리 성능 평가

위성정사영상 생산 및 처리시간을 측정하기 위해, 시스템에 영상이 입력된 시점으로부터 정밀보정영상, 정밀정사영상(위성정사영상)이 생산되기까지의 시간을 측정하였다. 표 1-1은 본 실험을 위해 사용한 하드웨어 사양을 나타낸다. 정밀영상생산시스템의 영상처리에 소요되는 시간을 확인한 결과, 정밀보정영상(Level 2R) 생산까지는 약 10분, 위성정사영상(Level 2G) 생산까지는 약 20분이 소요되는 것으로 나타났다. 현재 국토위성센터의 정밀영상생산시스템은 동시에 6장의 영

상을 처리할 수 있는 병렬식 구조로 되어있고, 이는 국토위성이 한반도를 통과하여 Strip 촬영하는 경우 약 50장의 영상이 취득되었을 때 위성정사영상으로 가공하는데 약 2.7시간이 소요됨을 의미한다. 시스템 도입 당시에는 국토위성센터에서 기본영상 생산을 할 수 있도록 전산자원이 도입되었으나, 이후 국토위성센터는 기본영상을 수신하여 위성정사영상으로의 가공만을 수행함에 따라 해당 자원을 위성정사영상 가공에 활용할 수 있을 것으로 보인다. 전산자원의 효율적 운영을 수행하는 경우 위성정사영상 처리에 소요되는 시간을 단축할 수 있을 것으로 예상된다.

<표 1-1> 실험에 사용한 H/W 자원

하드웨어 종류	사양
CPU	Intel i-7 8700K @ 3.7GHz
GPU	NVIDIA GTX 1070
RAM	32GB
Storage	HDD 2TB
OS	Windows 10 Pro

다음으로 모의영상(다목적실용위성 3호 및 3A호)을 기반으로 자동으로 처리된 위성정사영상의 성공률을 확인하였다. 총 158장의 대상 영상 중 북한 나선지역의 1장을 제외하고는 모두 처리가 완료되어 약 99%가 자동 정밀정사영상 생산에 성공했다. 북한 나선지역 영상은 정밀기하보정을 위한 최소 수량의 기준점 부족으로 정밀정사영상 생산에 실패한 것으로 확인하였다. 모의영상은 신규 촬영하는 국토위성과 달리 이미 영상 내 육지의 비율이 높고, 구름의 영향이 매우 적은 영상만을 취하여 사용함에 따라 자동 위성정사영상 생산 성공률이 매우 높게 나타났다. 국토위성영상을 기반으로 위성정사영상을 생산한 결과 총 634장의 영상 중 549장(약 86.6%)이 자동 생산에 성공하였다. 나머지 85장의 영상 중 16장은 영상융합이 불가능한 것으로 나타났고, 60장은 GCP Chip 부족, 9장은 구름 등의 영향으로 위성정사영상이 생산되지 않은 것으로 나타났다. 그림 1-5는 위성정사영상이 자동으로 생산되지 않은 사례의 영상을 나타낸다. 정밀기하보정에 필요한 GCP Chip의 최소 수량이 만족되지 않을 것으로 예상되는 해안지역 및 접경지역 등에 있어서는 GCP Chip 및 처리 알고리즘의 보완이 필요하다.

자동으로 생산된 위성정사영상의 센서모델 정확도(위성정사영상과 매칭에 사용된 GCP chip의 차이)는 기본영상이 보유하고 있는 초기 센서모델 정확도(최대 300pixel, 평균 60pixel)에 비해 약 10배 이상(최대 약 3pixel, 평균 1.5pixel) 개선된 것으로 나타났다. 지역적으로는 남한지역의


정밀 센서모델의 정확도(평균 1.3pixel)가 북한지역 대비(평균 1.7pixel) 높은 것이 확인되었다.



<그림 1-5> GCP Chip 부족으로 위성정사영상이 자동생산되지 않은 경우
(좌) 기상 영상으로 영상융합 불가능 (중) 해양지역 (우) 산간지역

나. 위성정사영상의 정확도 분석

위성정사영상의 위치정확도를 평가하기 전에 정밀영상생산시스템의 중간 산출물 중 하나인 영상융합 결과를 확인하였다. 그림 1-6은 10월 29일에 국토위성으로 촬영한 영상으로, 영상에 포함된 사각형의 Tarp 경계를 통해 영상융합 결과를 확인할 수 있다.



<그림 1-6> 국토위성의 영상융합 결과 [위](좌) 영상융합 전 (우) 정밀영상생산시스템 처리 결과
[아래](좌) Gram-Schmidt 알고리즘 (우) NNDiffuse 알고리즘

정밀영상생산시스템의 영상융합 알고리즘 적용 결과, 저해상도 다중분광 영상이 고해상도 전 정색 영상과 유사하게 해상도가 향상됨을 확인할 수 있었다. 그러나 영상 내 선명한 직선 부분을 확인한 결과 뭉개짐을 확인할 수 있었고, 상용소프트웨어에서 제공되고 있는 Gram-Schmidt 및 NNDiffuse 알고리즘과 비교했을 때에도 성능이 낮음을 확인할 수 있었다. 영상융합에 적용되는 밴드별 가중치 및 내삽기법 등에 있어서 추가 연구와 알고리즘 개선이 필요할 것으로 사료된다.

모의영상을 기반으로 위성정사영상과 GCP Chip 및 1/5,000 수치지형도와의 비교를 통한 위치정확도를 평가하였다. 그 결과, 영상별로 평균 약 1m~5m의 위치오차가 나타나는 것을 확인하였으며, 비교 대상이 다름(GCP Chip과 수치지형도)으로 인한 차이는 나타나지 않았다(표 1-2). 영상별로 인천, 전남, 제주와 신의주 지역은 1m이내의 위치오차를 갖는 것으로 확인했으나, 서울지역의 경우 위치정확도가 약 5m 정도로 나타났다. 또한 북한지역의 평양, 원산영상의 위치 정확도가 남한지역의 인천, 전남 영상보다 좋지 않은 것을 확인할 수 있다.

<표 1-2> 모의영상 기반 위치정확도 분석 결과


영상 ID	지역	위성정사영상 vs GCP chip				위성정사영상 vs 수치지형도			
		최대	최소	평균	표준편차	최대	최소	평균	표준편차
C1_20190120043558_21100_00056047	평양	4.7	0.9	2.4	1.1	4.3	0.8	2.1	1.2
C1_20190223045415_21614_00066626	신의주	2.0	0.6	1.3	0.4	2.8	0.7	1.8	0.9
C1_20181102041548_19906_00147222	원산	6.1	0.5	2.2	1.4	3.7	1.1	2.5	1.1
C1_20200508041443_28263_00041150	강원	4.1	1.0	2.2	1.1	7.6	0.6	2.6	1.8
C1_20151229044555_04205_00003616	파주	7.4	0.5	2.3	1.6	4.5	0.5	1.5	1.0
C1_20151211044753_03933_00020757	서울	9.1	0.6	4.9	2.3	8.6	0.3	4.9	2.3
C1_20180127044122_15690_00040490	인천	1.5	0.1	1.0	0.4	2.1	0.1	1.1	0.7
C1_20190324042830_22052_00188346	전남	2.4	0.6	1.4	0.6	3.4	0.1	1.1	0.9
C1_20170303045122_10703_00054714	제주	2.0	0.3	1.0	0.8	-	-	-	-
C1_20160530044124_06517_00023477	충남	5.8	1.5	3.6	1.6	5.1	0.5	3.1	1.8

표 1-3은 국토위성으로 촬영한 영상을 위성정사영상으로 가공하여 1/5,000 수치지형도와 비교한 결과를 나타낸다. 기하조건은 촬영당시 위성의 자세를 나타내며, R은 Roll tilt, P는 Pitch tilt, Y는 Yaw tilt를 의미한다. 별도로 명시되지 않은 tilting 각은 $\pm 3^\circ$ 이내이다. 앞서 표 1-2에서 제시된 모의영상의 위치정확도 분석 결과와 유사하게 영상별로 평균 약 1m~5m의 위치오차가 나타나는 것을 확인할 수 있었다. 직하로 촬영된 10월 11일 청진 영상과 10월 29일 순창 영상은 1m 내외의 높은 정확도를 나타냈다. 청진 영상 중에서 10° 내외의 Roll 또는 Pitch 기동을 한 경우에는 약 1.5m~2m의 위치정확도를 나타냈고, 청진·평양·서울 영상에서 20° 내외의 기동을 한 경우에는 3m 이상의 차이가 발생하였다. 그림 1-7은 청진 지역을 촬영한 6개의 영상에서 동일한 지점의 위치정확도를 확인한 것이다. 해당 지점에서는 직하로 촬영한 경우에 약 1.5m의 오차가 발생하였고, 14° 의 Roll 기동 및 10° 의 Pitch 기동을 한 경우 0.9m 및 1.1m의 오차가 발생하였다. 23° 의 Roll 기동을 했을 때 6.4m로 가장 큰 오차가 발생하였으며, 20° 의 Pitch 기동 및 32° 의 Roll 기동 시 4m 및 3.4m의 오차를 확인하였다. 육안 판독 방식에 있어서 오차가 있을 수 있으나, 대체로 직하 촬영의 경우 1m 내외의 위치정확도를 나타내고, 촬영각이 직하 방향에서 20° 이상 차이가 나는 경우 3m 이상의 오차가 발생하는 것으로 요약할 수 있다.

서울의 경우, 국토위성 및 모의영상으로 촬영한 영상이 있어 동시에 위치정확도를 비교 평가하였다. 그림 1-8은 21년 10월 24일과 25일에 촬영된 국토위성영상 및 16년 1월 8일에 촬영된 모의영상과 1/5,000 수치지형도를 중첩한 것이다.


<표 1-3> 국토위성영상 기반 위치정확도 분석 결과

연번	촬영일	기하조건	지역	위성정사영상 vs 수치지형도	
				평균	표준편차
1	10월 11일	-	청진	1.1	0.4
2	10월 19일	R: 22°	평양	2.9	1.1
3	10월 21일	R: -23°	청진	3.2	2.0
4	10월 24일	R: 18°	서울	3.0	1.4
5	10월 25일	R: -26°	서울	3.5	1.2
6	10월 26일	R: -32°	청진	2.6	0.7
7	10월 29일	-	순창	0.6	0.4
8	10월 30일	P: -20°	청진	4.1	1.5
9	11월 4일	R: -14°	청진	1.4	0.4
10	11월 28일	P: -10°	청진	1.8	1.0




<그림 1-7> 청진지역 위성영상 및 1/5,000 수치지형도 [위] (좌) 직하 (중) Roll -14° (우) Pitch -10°
[아래] (좌) Roll -32° (중) Roll -23° (우) Pitch -20°

아래 그림 1-8의 지역에서 10월 24일의 위성정사영상은 수치지형도와 약 3.3m, 10월 25일 영상은 약 3.5m의 차이를 갖는 것으로 나타났다. 16년 1월 8일 촬영된 영상의 위성정사영상은 약 8.7m 오차를 나타내었으며, 이는 해당 영상 취득 시점의 촬영 기하의 영향인 것으로 사료된다.



<그림 1-8> 서울지역 위성정사영상 및 1/5,000 수치지형도 중첩 모습
(좌) 국토위성, 촬영일: 21.10.24, Roll 18° (중) 국토위성, 촬영일: 21.10.25, Roll -26°
(우) 모의영상(다목적실용위성 3A), 16.01.08 Roll -15° & Pitch -30°

그림 1-9는 위성정사영상에서 발생한 영상왜곡의 예시를 나타낸다. 정밀영상생산시스템은 정사보정을 위해서 DEM을 사용하는데, DEM의 종류가 다르거나(남한-5m, 북한-10m, 그 외 -30m 등 지역 및 해상도 상이) 그 경계에서 값이 크게 변화하는 경우 그림과 같은 영상왜곡이 발생한다. 정사보정으로 인해 발생하는 영상왜곡을 제거하기 위해서 DEM의 경계값 및 정밀영상생산시스템의 보완이 필요할 것으로 사료된다.



<그림 1-9> 이종 DEM 및 경계값 문제로 인해 발생하는 영상 왜곡 예시

4. 결 론

본 연구에서는 국토위성 지상국 시스템의 핵심인 정밀영상생산시스템의 위성정사영상 자동생산 성능과 위성정사영상의 위치정확도를 분석하였다. 모의영상 및 국토위성영상 처리에 있어 안정적으로 운영되고 있는 것으로 판단되며, 위치정확도는 직하 촬영의 경우 1m 내외를 만족하는 것으로 나타났다. 본 연구에서 확인한 바와 같이, 향후 위성정사영상의 안정적 생산을 위해 영상 내 구름 등에 대한 품질 평가가 선행되고, 산간지역 및 해안지역 등에서 GCP Chip 보완 및 알고리즘 개선이 필요하다. 또한, 위성정사영상의 위치정확도 향상을 위해 GCP Chip의 품질 평가 및 지속적 유지관리가 필요하며, 정밀영상생산시스템의 알고리즘 고도화가 필요하다. 국토위성센터는 지난 1년간 위와 같은 문제점을 확인하고 개선하기 위한 연구를 추진 중에 있으며, 위성의 본격 운영과 더불어 위성정사영상의 안정적 생산 및 위치정확도 향상을 위해 지속적으로 노력할 예정이다.

참고문헌

- 국토교통과학기술진흥원 (2020), 국토위성정보 수집 및 활용기술 개발
- 박형준, 손종환, 정형섭, 권기억, 이계동 & 김태정. (2020). 국토관측위성용 정밀영상생성시스템 개발. 대한원격탐사학회지, 36(5-2), 881-891.
- 신정일, 윤완상, 박형준, 오관영 & 김태정. (2018). KOMPSAT-3A 영상과 항공정사영상의 영상정합 성공률 향상 방법. 대한원격탐사학회지, 34(6-1), 893-903.

제2장

고해상도 광학위성 복사(대기)보정 기술현황 조사

1. 연구의 배경 및 목적
2. 주요 내용
3. 결론

1. 연구의 배경 및 목적

국토위성센터는 '21년 3월 발사한 국토위성의 활용성 제고를 위해 '국가기본도 활용을 위한 사용자 친화형 영상 제품 구축 기획연구'를 추진하고 있다. '사용자 친화형 영상 제품'의 구축 및 서비스는 원격탐사에 전문지식이 없는 일반인들도 위성영상을 쉽게 사용하고 편의성을 높이는 것이 그 목적이다(그림 2-1). 현재 위성영상의 이·활용은 영상기반의 전문지식이 요구되고 데이터를 준비하는데 많은 시간이 소요되는 등 사용 편의성 및 활용도가 낮아 보다 쉽게 사용할 수 있는 산출물의 필요성이 대두되고 있다. 국제적으로도 이와 같은 문제점을 해결하고 위성영상의 활용을 촉진하고자 관련 분야에 대한 관심이 매우 높다.



<그림 2-1> 사용자 친화형 영상 제품 서비스 전/후 사용자 편의성 차이

국제지구관측위성위원회(CEOS)는 타 위성과 상호운용가능하고 사용자가 최소한의 노력으로 위성영상을 분석할 수 있도록 광학과 SAR위성 제품군의 사양을 정의하고 있으며, 이러한 기준을

만족하는 제품을 ARD(Analysis Ready Data)로 정의하고 있다. 국토위성센터는 CEOS가 정의하는 ARD 개념을 국토위성에 적용하여 ‘사용자 친화형 영상 제품’으로 정의하고자 한다. 다만 현재 CEOS에서 정의하는 제품군의 사양은 중해상도(공간해상도 < 10m) 중심이기 때문에, 고해상도 위성영상인 국토위성에 바로 적용하기는 어려워 규격에 대한 검토와 보완이 필요하다.

CEOS는 광학위성 제품군 사양을 일반 메타정보, 픽셀별 메타정보, 복사(대기)보정 정보, 기하보정 정보의 4가지 요소로 정의하고 있다. 이 중 기하보정은 현재 개발된 기술을 고도화하는 방향으로 추진하고 일반 및 픽셀별 메타정보는 제품 설계 사업을 통해 향후 정의할 계획으로, 현재 남아있는 과제는 복사(대기)보정이다. 복사(대기)보정을 거친 위성영상의 정보(표면반사율)는 지표면의 물리적 특성을 나타내는 표준화된 값을 나타낸다. 이러한 값은 사용자 입장에서 다른 부가처리 없이 위성영상을 즉시 활용할 수 있기 때문에 ARD에서 복사(대기) 보정은 반드시 필요한 사양이다. 이에 국토위성센터에서는 지난 9월부터 국토위성의 표면반사율 영상 생성 기술 개발 및 시범제작을 위해 사업을 추진하고 있으며, 본 연구에서는 복사(대기)보정과 관련한 문헌을 사전 조사한 결과를 보여주고자 한다.

2. 주요 내용

본 연구에서는 ① 복사(대기)보정의 일반적인 개념에 대해 선행 학습하고, ② 국내외 고해상도 위성영상의 대기보정과 관련한 기술 및 연구 동향을 검토하여 국토위성의 대기보정 가능성을 확인하였다.


가. 복사(대기)보정

위성으로부터 관측된 정보를 실제 지표면의 복사에너지와 공간 특성을 나타내는 의미 있는 정보로 표현하기 위해서는 복사왜곡과 기하왜곡에 대한 보정이 필요하며 이 과정을 전처리 작업이라고 부른다. 기하보정은 지구자전 또는 곡률 특성에 의해 야기되는 내부기하오차와 위성 기체의 자세변화에 의한 외부기하오차 등에 의한 기하학적인 왜곡을 줄여 위성에서 관측된 영상의 왜곡된 좌표를 적절한 평면 지도 상의 정확한 위치로 보정해 주는 것으로 고해상도 광학위성이 발달함에 따라 정확한 기하보정은 필수적이다. 복사보정은 크게 열손실, 행손실, 줄무늬 잡음 등 시스템 감지기에서 나타나는 오차에 대한 보정과 대기의 흡수와 산란, 지형에 의한 감쇠효과로 나타나는 대기보정으로 구분할 수 있다(Jensen 2016). 한국항공우주연구원에서는 전자의 복사보정을 수행한 표준영상(L1)을 생산하므로 본 연구에서는 후자인 대기보정에 대해 다루고자 한다.

대기보정의 방법은 크게 상대보정과 절대보정으로 나눌 수 있다. 상대보정은 단일 영상 내 밴드 간 또는 다중시기 영상 간 강도 값을 정규화 하는데 사용되며, 절대보정은 센서 보정계수와 복사전달모델에 근거한 대기보정 알고리즘 또는 경험적 선형보정을 말한다(Jensen 2016). 상대보정은 영상기반의 경험적 방법을 사용하며, 내부 평균반사도(Internal Average Relative Reflectance, IARR), 균일 영상 보정법(Flat Field Correction, FFC), 경험적 선형 접근법(Empirical Line Approach, ELA), QUAC(QUick Atmospheric Correction) 등이 있다(이권호 등 2019). FFC는 영상의 일부분에 분광학적으로 안정된 반사도를 가지는 지역이 있는 것으로 가정하고 그 지역의 평균 스펙트럼을 기준으로 다른 지역의 반사도 값을 산출하는 방법이며, IARR는 FFC와 유사하나 영상 전체의 평균스펙트럼을 기준으로 상대 반사도 값을 계산한다. 이 두 기법은 대기 관측자료 등 현지관측자료 없이 계산할 수 있으나 영상에 대기 흡수도의 특성을 포함하고 있다. ELA기법은 센서의 분광 복사량과 현장에서의 분광 반사도의 선형 회귀식을 도출하는 방식이며, 관측값을 사용하기 때문에 현장이나 실험실에서 측정된 반사도 값과 가장 유사한 분광 반사도를 산출할 수 있다. QUAC은 대기보정을 위한 매개변수를 영상 자체의 스펙트럼에서 직접 결정하는데, 영상의 조합된 반사도 값을 경험적으로 계산하는 방식으로 빠르다는 장점을 가지고 있다.

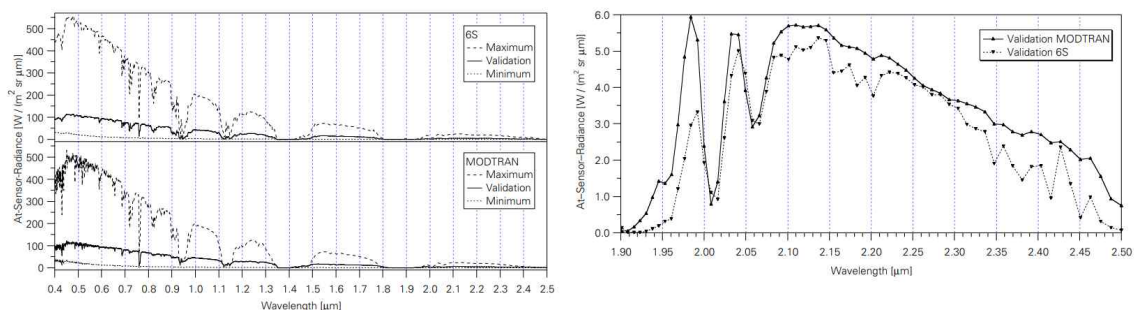
절대보정은 일반적으로 원격탐사 시스템에서 기록된 DN(Digital Number) 값을 비율 표면 반사도(Scaled surface reflectance)로 바꾸는 것이다. 이 때 대부분의 대기보정 프로그램은 MODTRAN(MODerate resolution atmospheric TRANsmittance) (Berk 등 1987) 또는 6S(Second Simulation of the Satellite Signal in the Solar Spectrum) (Vermote 등 1997)와 같은 복사전달모델로 생산된다.

MODTRAN은 미국 Spectral Sciences, Inc(SSI)와 미공군연구소(Air Force Research Laboratory)가 대기의 광학 관측자료를 분석하고 예측하기 위해 만든 컴퓨터 코드로 다중분광영상과 초분광영상의 대기보정 시스템이 내장되어있다(http://modtran.spectral.com/modtran_index). MODTRAN 소프트웨어는 자외선부터 적외선을 포함한 파장대의 투과도(Transmittance)와 복사휘도(Radiance)를 계산할 수 있다. 입력자료는 대기모델, 지표면 온도(K), 지표면 알베도, 에어로졸 모델, 가시거리, 센서고도, 센서천정각(sensor zenith)이다. 대기모델은 고도에 따른 온도(K), H₂O, O₃, CO₂, CO, CH₄를 6가지 모델(열대, 중위도 여름, 중위도 겨울, 아한대 여름, 아한대 겨울, US Standard 1976)로 구분하며, 에어로졸 모델은 4가지 모델(Rural, Urban, Navy, Desert) 중에 선택 가능하다. MODTRAN 사이트에서는 소프트웨어 데모 버전을 공개하고 있는데, 아래 그림은 이를 이용하여 중위도 여름에 Urban 에어로졸 모델을 이용하여 0.4 μ m~1.0 μ m까지 0.003 μ m의 해상도로 추출한 결과이다.



<그림 2-2> MODTRAN을 이용해 계산된 파장별 (좌) 투과도, (우) 복사휘도

6S는 대기를 통과한 광학 전자기 신호의 복사 전달을 정확하게 시뮬레이션 할 수 있는 코드 (computer code)로 프랑스의 Laboratoire d'Optique Atmospherique에서 개발한 5S(Simulation of the Satellite Signal in the Solar Spectrum)의 개선된 버전(Vermote 등 1997)이다. 6S는 목표고도, Non-Lambertian 표면 조건, 흡수종(O₂, O₃, H₂O, CH₄, N₂O, CO)을 고려하여 near-nadir 각에서의 항공기 및 위성 관측 값을 계산할 수 있다. 6S는 2.5nm의 스펙트럼 분해능에서 400-2,500nm 스펙트럼 범위의 대기 복사 전달을 시뮬레이션 할 수 있다. 6SV는 6S의 벡터 버전으로 이전 버전인 6S에 비해 에어로졸 산란 위상 함수의 설정에 사용되는 산란각의 수, 수직 에어로졸 프로파일의 고도 범위 등 세밀한 조건에 대한 복사휘도의 모의가 가능하며, 6S에서 고려하지 않은 복사휘도의 편광효과를 계산하여 정확도를 향상 시킨 것이다(정대성 외, 2020). 아래 그림은 Schaepman 등(1998)이 대기조건 등 동일한 입력조건 하에 MODTRAN 스펙트럼 분해능에서 두 모델의 복사휘도를 추출하고 비교한 그림이다.



<그림 2-3> (좌)동일 입력조건에서 MODTRAN과 6S의 복사휘도 결과 비교, (우) 1.9-2.5μm 확대
Schaepman 등(1998) 발췌

아래 표는 복사전달모델을 기반으로 한 주요 절대 대기보정 방법을 요약하였으며, ATCOR, FLASSH는 MODTRAN 모델이 ATREM, HATCH는 6S모델이 사용된 것을 알 수 있다.

<표 2-1> 복사전달모델 기반의 절대 대기보정

절대 대기보정	원리(복사전달모델)	참고문헌
ATREM (ATmosphere REMoval)	수증기 기반 대기 투과율 계산 6S 복사전달모델 기반	Gao and Goetz(1990) Gao et al(1993)
ATCOR (Atmospheric and Topographic CORrection)	에어로졸, 수증기 추정 지형고도에 따른 지형반사효과 고려 BRDF 보정, De-shadowing, Dehaze 모듈 포함 MODTRAN-4 기반 LUT 사용	Richter et al(2006)
FLASSH (Fast Line of sight Atmospheric Analysis of Spectral Hypercubes)	다중산란 효과가 고려된 지표반사도 산출 MODTRAN-4 기반 LUT 사용	Adler-Golden et al(1998; 1999)
HATCH (High-accuracy Atmospheric Correction for Hyperspectral Data)	난반사면 가정(Lambertian surface) HITRAN 2000 복사전달모델 기반	Goetz et al(2003) Qu et al(2003)

복사전달모델을 사용할 시에는 원격탐사 자료가 수집될 당시의 대기특성을 알아야 한다. 전자기파는 대기층을 통과하면서 다양한 대기입자(가스분자, 에어로졸, 수증기 등)에 의해 산란과 흡수가 발생하는데, 지표면에서 반사된 전자기에너지의 흡수량과 산란량을 산출할 수 있다면 센서에서 감지된 영상 신호에 포함된 대기영향을 제거할 수 있다(이규성 2019). 대기 입자 중 가스분자는 시공간적으로 변이가 적고 거의 고정적이기 때문에 계산이 용이하나, 에어로졸 및 수증기는 가변적이고 관측자료를 얻기 어렵다. 에어로졸 값의 획득 방법은 크게 지상관측자료를 사용하는 방법과 영상 내 추정 방법, 타 위성관측자료를 이용하는 방법이 있다. 지상관측자료는 AERONET을 통해 얻을 수 있는데 AERONET은 미국항공우주국(NASA)와 PHOTONS(PHOTomeires pour le Traitement Operationnel de Normalization Satellitaire)가 설립한 지상 기반 원격 감지 에어로졸 네트워크 연합으로 국제적인 기구, 연구소, 대학 등과 공동으로 데이터를 구축하고 있으며 국내 기상청 및 대학에서도 에어로졸 값을 측정하여 공유하고 있다. 영상 내 추정 방법의 가장 대표적인 알고리즘은 Dark Object로 반사율이 낮은 지표물에서 에어로졸의 영향을 많이 받는 분광밴드(가시광선)과 그렇지 않은 분광밴드(적외선)에서의 신호차를 이용해 에어로졸 두께를 추정하는 방법이며, 시공간적으로 일치하는 타 위성(AVHRR, MODIS 등)에서 산출되는 에어로졸 두께값을 이용하는 방법도 있다.


나. 국내외 연구동향

이권호 등(2019)은 대기보정과 관련된 기초자료를 제공하기 위해 국내외 주요 저널을 대상으로 키워드 검색을 통해 대기보정 기술 및 현황에 대해 분석하였다. 국내에서 발간된 논문의 경우 주로 Landsat과 SeaWiFs 위성 시리즈가 꾸준히 사용되어 왔으며, 천리안 위성이 발사된 후 대기보정 연구가 증가하여 2010년 국내 학술논문 발간 수가 연도별 최고 발간 수를 기록하였다. 해외에서 발간된 논문의 경우 국내와 마찬가지로 Landsat과 SeaWiFs 위성이 꾸준히 사용되어 왔으며 EOS 위성 발사 이후 연구 논문수가 증가되었고, 2010년 이후에는 드론, 항공기에 탑재된 센서의 대기보정 연구가 증가하고 있다.

1) 국내동향

Lee 등(2005)는 KOMPSAT-2 MSC(Multi-Spectral Camera)의 영상기반 대기보정 모델 적용가능성을 확인하기 위해 동일한 파장대역을 가지는 Landsat ETM+ 영상자료와 지상관측 Surface Reflectance 자료를 이용하여 실험하였으며 COST 모델 기반의 결과가 비교적 현장관측 자료와 일치하는 것을 확인하였다. 이선구 등(2006) 또한 KOMPSAT-2 발사를 앞두고 절대복사보정의 사전점검을 위해 Field Campaign을 수행하고 수집된 지표자료와 대기자료를 이용하여 MODTRAN 4.0 복사전달모델로부터 TOA(Top-of-Radiance)를 추출하였으며, Orbview-3 위성의 DN과 비교하여 절대복사보정계수를 산출 가능성을 분석하였다. 이후 천리안위성의 발사와 함께 해상탐재체와 기상탐재체의 대기보정 연구가 활발히 진행(이권호 등 2008, 민지은 등 2010, 김원국 등 2013, 이보람 등 2013, 김미진 등 2014)되었다. 특히 천리안 위성의 정지궤도 해상탐재체(GOCI)의 경우 일반적으로 센서에 입사되는 광신호의 약 90%가 대기에 의한 신호이며, 관측목적 해수에 의한 신호를 추출하기 위해서는 높은 복사보정 정확도가 요구되어(조성익 등 2012) 연구가 활발히 진행된 것으로 보인다. 2018년도 이후에는 위성과 함께, 항공기, 드론을 이용한 원격탐사가 증가하였다. 산림·농업분야에서 많이 사용되는 식생지수 등은 표면반사도가 TOA 보다 높은 정확도를 보이기 때문에 대기보정의 중요성이 강조되고 있으며(안호용 등 2018), 원하는 지역의 정보를 빠르게 획득하기 위해 항공기, 드론 등의 활용도가 높아지고 있다(이화선 등 2019, 조강준 등 2019, 전의익 등 2019).

최근에는 고해상도 광학 위성영상의 표면반사도 값의 필요성과 활용도가 높아지면서 KOMPSAT-3A를 이용하여 복사전달모델 적용한 대기보정(이기원 등 2019, 이기원 등 2020, 김광섭 등 2020), 복사전달모델 기반의 조건표 구축(정대성 등 2020) 등의 연구가 진행되고 있다.



<그림 2-4> Kompsat-3A 영상 (a) 대기보정 전, (b) 대기보정 후 (이기원 등 2019, Fig. 8. 발췌)

이기원 등(2020)은 Orfeo ToolBox 오픈 소스 확장 프로그램을 이용하여 KOMPSAT-3A 지표 반사도를 산출하고 RadCalNet RVUS 사이트에서 제공하는 지표반사도 값과 비교 검증하였으며, 같은 지역에서 같은 날 촬영된 Landsat-8 OLI 영상과 상대비교도 수행하였다. 이기원 등(2020)은 해당 연구 결과 KOMPSAT-3A와 RadCalNet의 지표반사도 값의 일치도가 Landsat-8 OLI 영상보다 높다는 점을 통해 Landsat-8 OLI 영상을 기준으로 KOMPSAT-3A의 상대검보정을 실시하는 것은 부적절하다고 시사하였다. 김광섭 등(2020)은 마찬가지로 Orfeo ToolBox 오픈 소스 확장 프로그램을 이용하여 3개의 KOMPSAT-3A 영상의 지표반사도를 산출하였다. 이 값은 RadCalNet의 BTCN 사이트에서 제공하는 지표반사도 값과 Landsat-8, Sentinel-2B 영상과 비교하였으며 밴드별 차이를 분석한 결과 95%의 정확도를 기준으로 근접한 결과를 보이는 것을 확인하였다.

정대성 등(2020)은 6S보다 정확도와 정밀도가 향상된 6SV(Vermote 등 2006) 복사전달모델 기반의 조건표(Look-Up Table)를 구축하였다. 복사전달모델 기반의 대기보정은 높은 정확도를 추출할 수 있지만 복잡한 처리과정으로 시간이 많이 소요된다. 따라서 대기보정 처리 시간을 단축하기 위해 정해진 대기/기하 조건에 대해 미리 계산하는 조건표를 사용하는 방법이 연구되고 있다. 정대성 등(2020)은 6SV기반의 조건표를 바탕으로 복사전달모델을 직접 모의한 결과와 비교하였으며, 에어로졸 광학두께에 민감하게 반응하는 Blue 밴드에서 상대오차가 크게 발생하는 것을 확인하였다. 이를 통해 밴드별로 대기조건, 특히 에어로졸 광학두께에 대한 민감도가 다르기 때문에 채널별로 조건표를 구축해야 한다고 판단하였다.

2) 국외동향

중해상도 광학위성인 Landsat-8과 Sentinel-2 위성의 대기보정은 현재 국제 프로그램(Atmospheric Correction Inter-Comparison Exercise, 이하 ACIX)을 통해 상호 비교·분석되고 있다. ACIX는 Landsat-8, Sentinel-2 위성 정보로부터 국제적으로 사용되는 다양한 대기보정 프로세스를 이용하여 산출된 표면반사도, 수증기, 에어로졸 두께 값을 상호 비교분석하기 위한 활동(Doxani 등 2018)으로 CEOS, NASA, ESA를 필두로 2016년 6월부터 2018년 2월까지 수행되었으며, 이후 2018년 10월부터 2021년 5월까지의 향상된 대기보정 프로세스를 이용하여 ACIX II Land/Water 활동이 진행되었다.

ACIX는 정확도 검증을 위해 AERORNET에서 관측된 정보를 Ground Truth 자료로 사용하였으며, ACIX II에서는 RadCalNet 사이트도 추가되었다. 아래 표는 ACIX와 ACIX II 참가자(소속)와 그들의 대기보정 프로세서 리스트를 보여준다.

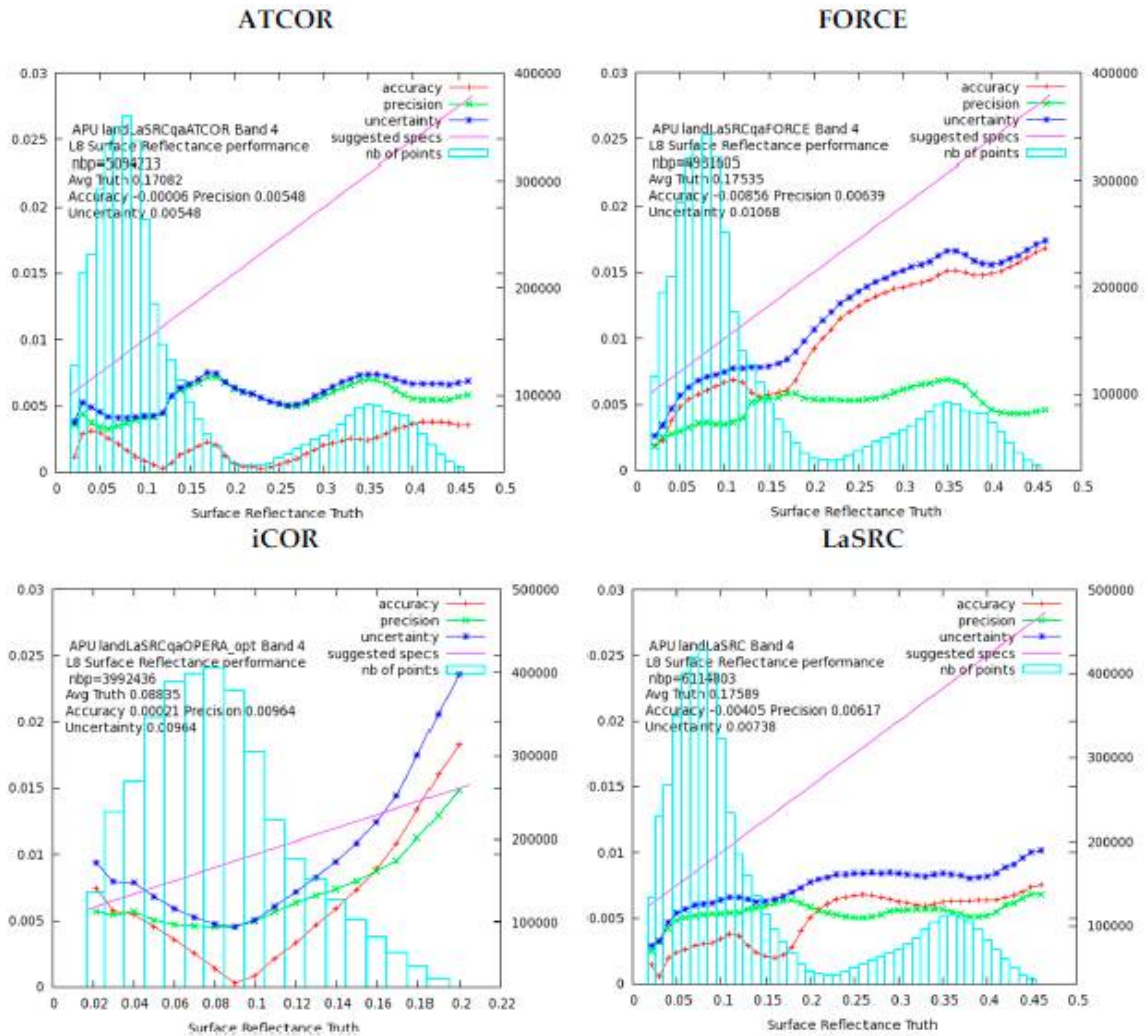
<표 2-2> ACIX 대기보정 프로세스 리스트 및 참가자(소속)

대기보정 프로세스	참가자	소속
ACOLITE	Quinten Vanhellmont	Royal Belgian Institute for Natural Sciences [Belgium]
ATCOR/S2-AC2020	Bringfried Pflug, Rolf Richter, Aliaksei Makarau	DLR German Aerospace Center [Germany]
CorA [Brockmann]	Grit Kirches, Carsten Brockmann	Brockmann Consult GmbH [Germany]
FORCE	David Frantz, Joachim Hill	Trier University [Germany]
iCOR [OPERA]	Stefan Adriaensen	VITO [Belgium]
GA-PABT	Fuqin Li	Geoscience Australia [Australia]
LAC	Antoine Mangin	ACRI [France]
LaSRC	Eric Vermote	GSFC NASA [USA]
MACCS	Olivier Hagolle	CNES [France]
GFZ-AC [SCAPE-M]	André Hollstein	GFZ German Research Centre for Geosciences [Germany]
SeaDAS	Nima Pahlevan	GSFC NASA [USA]
Sen2Cor v2.2.2	Jerome Louis, Bringfried Pflug	Telespazio France [France], DLR German Aerospace Center [Germany]

<표 2-3> ACIX II Land 대기보정 프로세스 리스트 및 참가자(소속)

대기보정 프로세스	참가자	소속
Acomp	Fabio Pacifici	DigitalGlobe [USA]
ATCOR	Bringfried Pflug	DLR Remote Sensing Technology Institute [Germany]
EMBAC	Kim Minsu	USGS [USA]
FORCE	David Frantz	Humboldt-University [Germany]
iCor	Liesbeth Dekeukelaere Erwin Wolters	VITO [Belgium]
LaSRC	Eric Vermote Jean-Claude Roger Sergii Skakun	NASA GSFC [USA] Maryland University [USA]
MAJA	Olivier Hagolle Aimé Meygret	CNES/CESBIO [France]
Overland	Hervé Poilvé	Airbus Defence and Space [France]
Planet SR	Alan Collison	Planet [USA]
Sen2Cor	Jérôme Louis Bringfried Pflug	European Space Agency (ESA), Telespazio [France] DLR Remote Sensing Technology Institute [Germany]
SIAC	Feng Yin	University College London [UK]
SMAC-G/MERRA2	Didier Ramon	HYGEOS [France]

ACIX에서는 AERONET 측정자료와 동시기에 관측된 Landsat-8, Sentinel-2 자료를 사용하였다. 이때 AERONET의 태양광도계(Sunphotometer)를 중심으로 9km × 9km 영상을 일부 잘라 구름, 구름 그림자, 눈, 물, 높은 에어로졸로 분리된 픽셀을 제외한 표면반사율 값의 평균값과 비교하였다. 알고리즘의 정확도는 비교 결과는 그림 2-5와 표 2-4와 같이 표현되며, A, P, U(이하 APU)는 각각 정확도(Accuracy), 정밀도(Precision), 불확실도(Uncertainty)를 의미한다. 모든 사이트에서의 대기보정 프로세스 별, 위성 밴드별 결과는 <https://calvalportal.ceos.org/results>에서 확인할 수 있다. 그림 2-5에서 자홍색(Magenta) 선은 이론상 허용하는 오차 범위(여기서는 $0.005 + 0.05 \times \rho$, ρ 는 표면반사율로 계산)을 나타내며, 일반적으로 APU선이 자홍선을 넘지 않으면 결과가 좋은 것으로 간주한다(Doxani 등 2018).

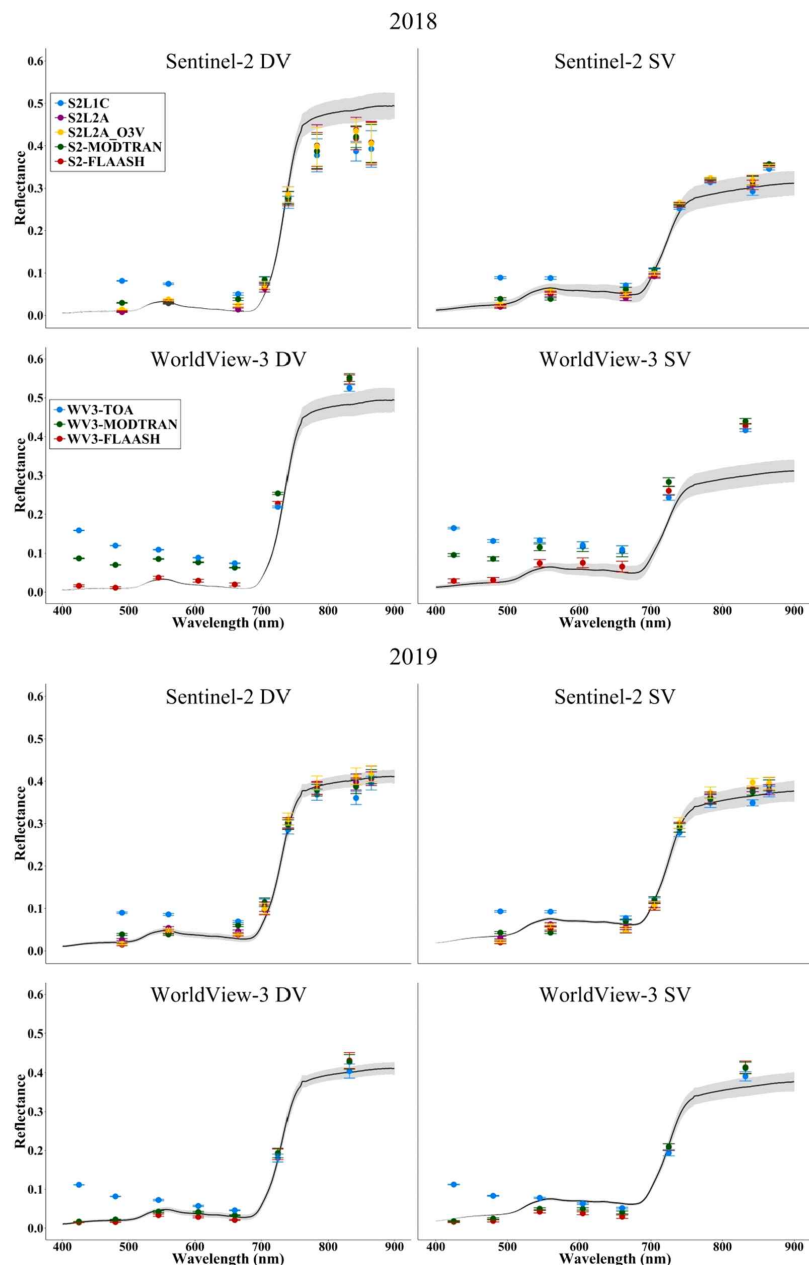


<그림 2-5> Landsat-8 Band 4에서의 ATCOR, FORCE, iCOR, LaSRC의 표면반사율 비교결과(예시)

<표 2-4> Landsat-8 Band 4에서의 ATCOR, FORCE, iCOR, LaSRC의 APU값(예시)

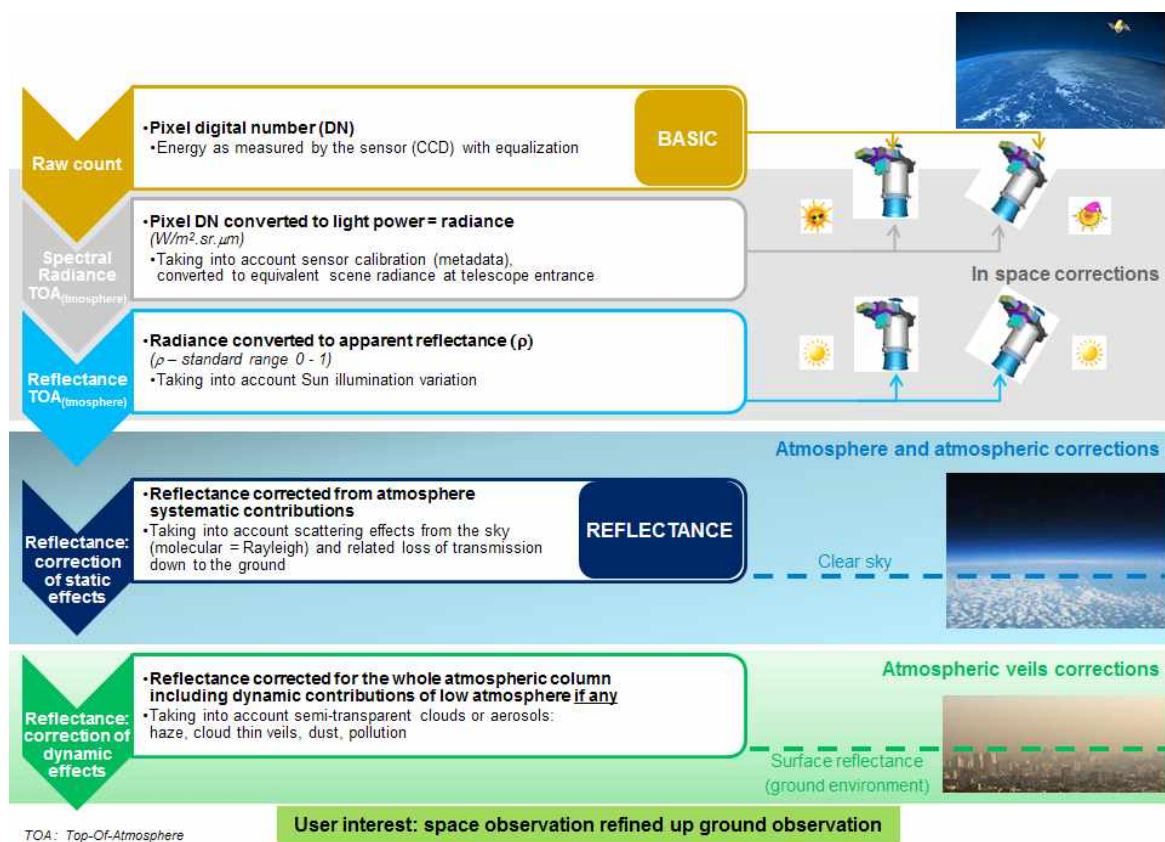
OLI Band		ATCOR	FORCE	LaSRC	iCOR
nbp		5094039	4981438	6109550	3985227
1	A	0.009	0.009	-0.005	-0.004
	P	0.010	0.008	0.010	0.011
	U	0.013	<u>0.012</u>	<u>0.012</u>	<u>0.012</u>
2	A	0.001	-0.001	-0.004	-0.004
	P	0.007	0.006	0.009	0.010
	U	0.007	<u>0.006</u>	0.010	0.010
3	A	0.000	-0.009	-0.004	0.000
	P	0.005	0.006	0.007	0.009
	U	<u>0.005</u>	0.010	0.008	0.009

위와 같은 위성영상 간 상호 비교는 고해상도와 중해상도 위성 간에서도 시도되었다. Pancorbo 등(2021)은 Sentinel-2와 Worldview-3 위성영상에 MODTRAN, FLASSH, Sen2Cor (Sentinel-2에만 적용) 대기보정 모델을 적용하여 지상관측자료와 비교하였으며, Sentinel-2와 Worldview-3의 지표반사도의 조화값을 추정하였다. 지상관측은 식생이 희박한 지역(Sparse Vegetation, SV)과 조밀한 지역(Dense Vegetation, DV)에서 수행되었으며, 아래 그림 2-6은 해당지역에서의 지상관측자료와 대기모델을 이용하여 산출된 반사도 값을 비교한 예시이다.



<그림 2-6> 지상관측자료(실선)와 대기보정모델 적용 결과(점) 예시

민간기업에서도 대기보정된 지표반사도의 가치를 인지하고 표면반사율 산출물을 제공하고 있다. AIRBUS 社の Pleiades 위성(GSD 0.7m(PAN), 2.8m(MS) at nadir)은 그림 2-7과 같이 복사보정 산출물을 정의하고 있다(Pleiades Imagery User Guide, AIRBUS). Pleiades는 복사보정과 관련하여 3가지(Basic, Reflectance, Display)의 주문 옵션을 선택할 수 있는데, Basic은 위성 센서에서 관측된 에너지인 DN값을 제공하여, Reflectance는 대기보정된 값, Display는 8bit의 트루컬러(True Color)로 사용자가 보기 좋게 최적화된 색상으로 표현된 것으로 물리적 의미의 값은 아니다. 그림 2-7에서 보는 것과 같이 Pleiades는 Reflectance 값을 Static effect와 Dynamic effect로 구분하고 있다. 여기서 Reflectance 산출물은 전자를 의미하는데, LOWTRAN 류(MODTRAN, ACTOR 등) 또는 5S-6S 대기보정 모델을 사용하여 계산되었다. 이때 대기보정 모델은 표준기압, 영상의 평균 지상고도 및 태양 조도, 위성자세의 실험적 평균 매개변수로부터 추정되며, 지상 관측 자료는 사용하지 않는다. 이렇게 계산된 Reflectance 값은 청천 영상의 경우 표면반사율 값과 동질화 할 수 있다고 하였다(Pleiades Imagery User Guide, AIRBUS.)



<그림 2-7> 센서로부터 지표면 물리값으로 보정과정

3. 결론

국토위성센터는 고해상도 위성영상의 활용과 공급을 담당하는 주 활용기관으로서 ‘사용자 친화형 영상 제품 구축’을 통해 누구나 위성영상을 쉽게 사용 가능하도록 기하왜곡과 복사왜곡을 제거한 국토위성 영상을 제공하고자 한다. 기하보정의 경우 기존에 R&D사업을 통해 개발된 기술을 고도화하여 높은 정확도와 안정도를 가질 수 있을 것으로 기대되나 대기보정은 아직까지 도전과제로 남아있다. 특히 고해상도 위성의 경우 중·저해상도에 비해 복잡한 지표 특성을 가지고 있어 과거 중해상도에 적용된 대기보정 알고리즘의 비교 및 평가가 선행되어야 한다.

이에 본 연구는 복사(대기)보정에 대한 일반적인 개론을 정리하고, 국내외 대기보정에 대한 현황을 조사하였다. 국내의 경우 천리안 위성의 발사와 함께 대기보정에 대한 연구가 활발히 진행되었는데, 특히 해색탐제체에서 순수한 해수면 신호 값을 얻기 위해서는 대기보정이 불가피하기 때문인 것으로 나타났다. 최근 산림과 농업분야에서 드론과 항공기의 활용도가 높아지고 있어, 높은 해상도와 정확도를 가지는 표면반사율 영상의 중요도가 증가하고 있다. 이와 함께 Kompsat-3A 등 국내 고해상도 광학위성의 대기보정 연구가 비교적 최근에 진행되고 있으며, 유사한 스펙인 국토위성의 대기보정도 가능할 것으로 판단된다.

국외에서는 가용 위성이 다양해지고 위성영상간의 상호운용성 확보를 위해 지표의 물리적인 값을 반영하는 표면반사율 영상의 필요성이 급부상하고 있다. 이를 위해 다양한 대기보정 알고리즘을 적용한 결과를 상호 비교하는 활동과 연구가 추진되고 있으며, 최근에는 중해상도 영상과 고해상도 영상의 장단점을 보완하고 조화를 찾는 연구도 수행되었다.

국토위성센터는 고해상도 영상의 대기보정의 가능성을 확인하고 실제 국토위성을 이용해 표면반사율 영상을 시범 제작하고자 한다. 표면반사율 영상은 향후 픽셀단위정보와 함께 사용자 친화형 영상 제품으로 공공/민간에 배포할 예정이며, 이를 통해 일반 국민들의 위성영상 접근 문턱을 낮추고 위성영상의 활용 저변을 확대하기 위한 최소한의 기반 마련하는데 기여할 것으로 기대된다.

참고문헌

- 김광섭, & 이기원. (2020). 다목적실용위성 3A 영상 자료의 지표 반사도 성과 검증: RadCalNet Baotou (BTCN) 자료 적용 사례. 대한원격탐사학회지, 36(6), 1509-1521.
- 김미진, 김준, & 윤종민. (2014). 천리안위성 기상 탑재체의 가시 채널 관측을 이용한 지표면 반사도 산출. Korean Journal of Remote Sensing, 30(5), 627-639.
- 김원국, & 이상훈. (2013). 위성센서 대리 검보정을 위한 소노란 사막의 복사 가변성 연구. Korean Journal of Remote Sensing, 29(2), 209-218.
- 민지은, 유주형, & 안유환. (2010). 정지궤도 해색탐재체 (GOCI) 자료를 위한 대기 및 BRDF 보정 연구. 대한원격탐사학회지, 26(2), 175-188.
- 안호용, 나상일, 박찬원, 소규호, & 이경도. (2018). 다중분광위성자료의 대기보정에 따른 반사도 및 식생지수 분석. 대한원격탐사학회지, 34(6), 981-996.
- 이규성. (2019). 육상 원격탐사에서 광학영상의 대기보정. 대한원격탐사학회지, 35(6), 1299-1312.
- 이권호, & 김영준. (2008). COMS/GOCI 관측값의 대기 에어러솔의 특성에 대한 민감도 분석. 대한원격탐사학회지, 24(6), 559-569.
- 이권호, & 염종민. (2019). 인공위성 원격탐사를 이용한 대기보정 기술 고찰. 대한원격탐사학회지, 35(6), 1011-1030.
- 전의익, 김경우, 조성빈, & 김성학. (2019). 드론 초분광 영상 활용을 위한 절대적 대기보정 방법의 비교 분석. 대한원격탐사학회지, 35(2), 203-215.
- 이기원, & 김광섭. (2019). 오픈소스 기반 다목적실용위성 3A호 영상자료의 지표면 반사도 영상 제작 실험. 대한원격탐사학회지, 35(6-4), 1327-1339.
- 이기원, & 김광섭. (2020). RadCalNet 자료를 이용한 다목적실용위성 3A 영상 자료의 지표 반사도 성과 검증. 대한원격탐사학회지, 36(2), 167-178.
- 이보람, 안재현, 박영제, & 김상완. (2013). GOCI 영상의 탁한 해역 대기보정: MUMM 알고리즘 개선. Korean Journal of Remote Sensing, 29(2), 173-182.
- 이선구, & 김용승. (2006). Absolute Radiometric Calibration 을 위한 Field Campaign 과 시험결과. 항공우주기술, 5(2), 213-219.
- 이화선, 서원우, 우충식, & 이규성. (2019). 산림 식생 모니터링을 위한 무인기 다중분광영상의 반사율 산출 및 평가. 대한원격탐사학회지, 35(6), 1149-1160.
- 전의익, 김경우, 조성빈, & 김성학. (2019). 드론 초분광 영상 활용을 위한 절대적 대기보정 방법의 비교 분석. 대한원격탐사학회지, 35(2), 203-215.

- 정대성, 진동현, 성노훈, 이경상, 서민지, 최성원, ... & 김보람. (2020). KOMPSAT-3/3A 채널 별 6SV 조건표의 지표반사도 민감도 분석. *대한원격탐사학회지*, 36(5), 785-791.
- 조강준, & 김용일. (2019). Sen2Cor 대기보정 프로세서 평가를 위한 항공 초분광영상 기반 Sentinel-2 모의영상 생성 및 TOA 와 BOA 반사율 자료와의 비교: 농업지역을 중심으로. *대한원격탐사학회지*, 35(2), 251-263.
- 조성익, 오은송, 안기범, 박영제, 안유환, & 유주형. (2012). 정지궤도위성용 해석센서의 궤도상 복사보정 운영 현황. *한국천문학회보*, 37(2), 231-231.
- Adler-Golden, S. M., Matthew, M. W., Bernstein, L. S., Levine, R. Y., Berk, A., Richtsmeier, S. C., ... & Hsiao-hua, K. B. (1999, October). Atmospheric correction for shortwave spectral imagery based on MODTRAN4. In *Imaging Spectrometry V* (Vol. 3753, pp. 61-69). International Society for Optics and Photonics.
- Berk, A., Bernstein, L. S., & Robertson, D. C. (1987). MODTRAN: A moderate resolution model for LOWTRAN. SPECTRAL SCIENCES INC BURLINGTON MA.
- Doxani, G., Vermote, E., Roger, J. C., Gascon, F., Adriaensen, S., Frantz, D., ... & Vanhellemont, Q. (2018). Atmospheric correction inter-comparison exercise. *Remote Sensing*, 10(2), 352.
- Gao, B. C., & Goetz, A. F. (1990). Column atmospheric water vapor and vegetation liquid water retrievals from airborne imaging spectrometer data. *Journal of Geophysical Research: Atmospheres*, 95(D4), 3549-3564.
- Gao, B. C., Heidebrecht, K. B., & Goetz, A. F. (1993). Derivation of scaled surface reflectances from AVIRIS data. *Remote sensing of Environment*, 44(2-3), 165-178.
- Goetz, A. F., Kindel, B. C., Ferri, M., & Qu, Z. (2003). HATCH: Results from simulated radiances, AVIRIS and Hyperion. *IEEE Transactions on Geoscience and Remote Sensing*, 41(6), 1215-1222.
- Jensen, J. R. (2016). 원격탐사와 디지털 영상처리. 시그마 프레스, 4, 189-273.
- Kim, S. H., Kang, S. J., Chi, J. H., & Lee, K. S. (2007). Absolute atmospheric correction procedure for the EO-1 Hyperion data using MODTRAN code. *대한원격탐사학회지*, 23(1), 7-14.
- Lee, H. S., & Lee, K. S. (2015). Atmospheric correction problems with multi-temporal high spatial resolution images from different satellite sensors. *대한원격탐사학회지*, 31(4), 321-330.
- Lee, K. J., & Kim, Y. S. (2005). 다중분광 자료를 이용한 영상기반의 대기보정 연구. *Aerospace Engineering and Technology*, 4(1), 211-220.

- Mahiny, A. S., & Turner, B. J. (2007). A comparison of four common atmospheric correction methods. *Photogrammetric Engineering & Remote Sensing*, 73(4), 361-368.
- Manakos, I., Manevski, K., Kalaitzidis, C., & Edler, D. (2011, April). Comparison between atmospheric correction modules on the basis of worldview-2 imagery and in situ spectroradiometric measurements. In 7th EARSeL SIG Imaging Spectroscopy Workshop (pp. 11-13).
- Martin, J., Eugenio, F., Marcello, J., Medina, A., Bermejo, J. A., & Arbelo, M. (2012, November). Atmospheric correction models for high resolution WorldView-2 multispectral imagery: a case study in Canary Islands, Spain. In *Remote Sensing of Clouds and the Atmosphere XVII; and Lidar Technologies, Techniques, and Measurements for Atmospheric Remote Sensing VIII* (Vol. 8534, p. 853400). International Society for Optics and Photonics.
- Pancorbo, J. L., Lamb, B. T., Quemada, M., Hively, W. D., Gonzalez-Fernandez, I., & Molina, I. (2021). Sentinel-2 and WorldView-3 atmospheric correction and signal normalization based on ground-truth spectroradiometric measurements. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 166-180.
- Qu, Z., Kindel, B. C., & Goetz, A. F. (2003). The high accuracy atmospheric correction for hyperspectral data (HATCH) model. *IEEE Transactions on Geoscience and Remote Sensing*, 41(6), 1223-1231.
- Richter, R., Schläpfer, D., & Müller, A. (2006). An automatic atmospheric correction algorithm for visible/NIR imagery. *International Journal of Remote Sensing*, 27(10), 2077-2085.
- Schaepman, M. E., de Vos, L., & Itten, K. I. (1998, October). APEX-Airborne PRISM Experiment: hyperspectral radiometric performance analysis for the simulation of the future ESA land surface processes earth explorer mission. In *Imaging spectrometry IV* (Vol. 3438, pp. 253-262). International Society for Optics and Photonics.
- Vermote, E. F., Tanré, D., Deuze, J. L., Herman, M., & Morcrette, J. J. (1997). Second simulation of the satellite signal in the solar spectrum, 6S: An overview. *IEEE transactions on geoscience and remote sensing*, 35(3), 675-686.
- Vermote, E. F. T. D., Tanré, D., Deuzé, J. L., Herman, M., Morcrette, J. J., & Kotchenova, S. Y. (2006). Second simulation of a satellite signal in the solar spectrum-vector (6SV). *6S User Guide Version*, 3(2), 1-55.

제3장

이종 위성영상 융합 활용을 위한 교차검보정 기초 연구

1. 연구의 배경 및 목적
2. HLS 프로젝트 소개
3. 국토위성과 타 지구관측위성 간 융합 활용을 위한 기술 조사
4. 결론 및 기대효과

이종 위성영상 융합 활용을 위한 교차검보정 기초 연구

1. 연구의 배경 및 목적

지구관측위성을 기반으로 주기적인 국토 모니터링을 위해서는 시계열 영상 자료가 필요하지만 단일 위성의 영상만으로는 시계열 영상 자료의 구축이 어렵다. 특히 고해상도 지구관측위성은 공간 해상도가 높은 반면에 촬영면적이 좁아 동일지점의 주기적인 시계열 영상 확보가 제한적이다. 최근 다중분광센서를 탑재한 지구관측위성의 수가 증가하고 자료를 획득할 수 있는 경로가 다양해짐에 따라 시계열 영상을 기반으로 한 국토 모니터링 분야에서 위성영상의 활용성이 증대되고 있다.


가시광선과 근적외선 대역을 주로 관측하는 광학위성은 동일한 밴드 구성을 가지더라도 서로 다른 분광대역, 공간 및 시간해상도를 가지기 때문에 타 위성영상을 융합하여 활용할 경우 각 위성이 가지는 고유의 센서 특성 차이를 극복해야 한다 (안호용 등 2020). 특히, 각 위성이 가지고 있는 각각의 밴드 대역의 차이가 작더라도 식생지수와 같은 분광지수에 큰 영향을 미치기 때문이다 (Galvao *et al.*, 1999). 그에 따라 위성영상 간의 융합 활용을 위해서는 각 위성이 가지는 고유의 방사적인 센서 특성 차이를 보정해주는 과정이 필요하다. 뿐만 아니라 공간해상도와 참조 좌표계가 상이함에 따라 기준 영상을 선정하여 해당 영상을 기준으로 동일한 공간해상도, 기준 타원체, 투영법을 동일하게 맞춰주는 과정이 필요하다 (안호용 등 2020). 이를 통해 시계열 자료로서 필요한 요건을 갖추게 되면, 국토 및 자원, 재난 등의 지속적인 모니터링이 가능하게 된다. 국토위성 또한 시계열 자료로 활용되기 위해서는 다목적 실용위성, 또는 차세대중형위성군 등 다른 분광대역폭과 시간 및 공간해상도를 갖는 위성자료와의 융합이 필요하고, 이를 위해서 각 센서의 특성(방사적, 기하적 등)들이 고려되어야 한다.

따라서 본 연구에서는 향후 국토위성 영상과 타 위성영상의 융합 활용을 위한 기초연구로서 융합 활용의 대표적인 프로젝트인 HLS (Harmonized Landsat Sentinel-2) 프로젝트에 대해 조사하고 국토위성과 타 위성간의 교차검보정 기술 현황 조사를 통해 국토위성의 적용 가능성을 분석하고자 한다. 또한, 차세대중형위성군에서 국토위성과 같이 광학 센서로 구성되어 있는 농림위성과의 융합 활용을 위해 농림위성 활용기관의 연구 사업을 분석하고 각 위성센터들 간의 주 연구분야를 고려한 역할분담을 통해 도출 가능한 프로젝트를 구상하였다.

2. HLS 프로젝트 소개

가. HLS 프로젝트 개요

HLS (Harmonized Landsat Sentinel-2) 프로젝트는 미국 항공우주국(NASA, National Aeronautics and Space Administration)과 미국 지질조사국(USGS, United States Geological Survey)의 Landsat-8 OLI (Optical Land Imager)위성과 유럽우주국(ESA, European Space Agency)의 Sentinel-2 MSI (Multi Spectral Imager) 위성을 이용하여 조화되고 분석 준비가 완료된 표면 반사율 데이터 산출물을 생성하는 프로젝트이다. 본 프로젝트는 Landsat-8과 Sentinel-2 간의 스펙트럼 유사성을 통해 두 센서의 데이터를 조화시켜 관측 주기를 단축시키는 것을 목적으로 한다 (그림 3-1).

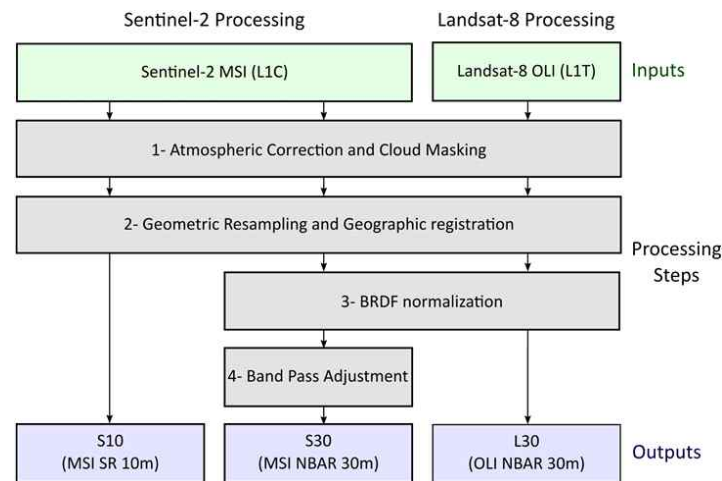


<그림 3-1> Landsat 7호, 8호 밴드와 Sentinel-2 밴드 대역 비교

※ 출처 : 미국 지질조사국, 2015

HLS 프로젝트 참여 기관은 미국 지질조사국, 미국 항공우주국, 유럽 우주국이다. 미국 지질조사국은 Landsat-8 자료를 제공하고 대기보정 알고리즘 개발을 수행해왔으며 미국 항공우주국은 HLS 알고리즘 전반에 대한 개발을 수행해왔다 (Claverie *et al.*, 2018). 유럽 우주국은 Sentinel-2 자료를 제공하였다. HLS 프로젝트를 통해 제작된 산출물은 NASA Earthdata Search에서 무료로 제공 받을 수 있다.

나. HLS 프로젝트 산출물



<그림 3-2> HLS프로젝트 영상 처리 과정

HLS 프로젝트는 그림 3-2와 같은 영상 처리 과정을 통해 2개의 산출물(S30과 L30)이 제작된다. HLS 프로젝트로 통해 제작된 S30은 Sentinel-2 (L1C) 제품을 입력자료로 하여 Landsat-8의 공간해상도(30m), 분광대역으로 맞춘 산출물로서 한 마디로 Sentinel-2 영상을 Landsat-8화 한 표면반사율 자료이다. L30은 Landsat-8 (L1T) 제품을 입력자료로 Sentinel-2 타일링 시스템으로 영상을 자른 표면반사율 자료이다. 표 3-1은 기존 Landsat-8 (OLI)과 Sentinel-2 (MSI) 영상의 각 밴드별 파장 대역과 프로젝트 산출물인 L30, S30의 밴드별 파장 대역 구성도를 나타낸 것이다.

<표 3-1> 기존 밴드 구성과 HLS 산출물 밴드 구성 비교

Band	Wavelength (μm)	OLI Band Number	MSI Band Number	HLS Band Code Name L30	HLS Band Code Name S30
Coastal Aerosol	0.43 – 0.45	1	1	band01	B01
Blue	0.45 – 0.51	2	2	band02	B02
Green	0.53 – 0.59	3	3	band03	B03
Red	0.64 – 0.67	4	4	band04	B04
Red-Edge 1	0.69 – 0.71	–	5	–	B05
Red-Edge 2	0.73 – 0.75	–	6	–	B06
Red-Edge 3	0.77 – 0.79	–	7	–	B07
NIR Broad	0.78 – 0.88	–	8	–	B08
NIR Narrow	0.85 – 0.88	5	8A	band05	B8A
SWIR 1	1.57 – 1.65	6	11	band06	B11

※ 출처 : 미국지질조사국 (최근 방문날짜 : '21.06.03.)
(<https://lpdaac.usgs.gov/data/get-started-data/collection-overview/missions/harmonized-landsat-sentinel-2-hls-overview/>)

HLS 프로젝트 영상 처리과정은 크게 4개(① 대기보정 및 구름 마스크링 과정, ② 영상 재배열 과정, ③ BRDF (Bidirectional Reflectance Distributing Function) 보정 과정, ④ 밴드 대역폭 조정 과정)으로 구분된다.

□ 대기보정 및 구름 마스크링

L30과 S30은 Vermote *et al.* (2016)가 개발한 LaSRC (Land Surface Reflectance Code) 코드를 통해 대기보정 되었다. LaSRC는 6S (Second Simulation of a Satellite Signal in the Solar Spectrum) 복사전달모델과 Landsat-5와 Landsat-7에 적용되는 대기보정인 LEDAPS (Landsat Ecosystem Disturbance Adaptive Processing System) 알고리즘 기반으로 제작되었으며 에어로졸, 수증기, 오존 등 대기 중 산란에 영향을 미치는 요인들을 MODIS 영상으로부터 추정하여 대기보정을 수행하는 방법이다.

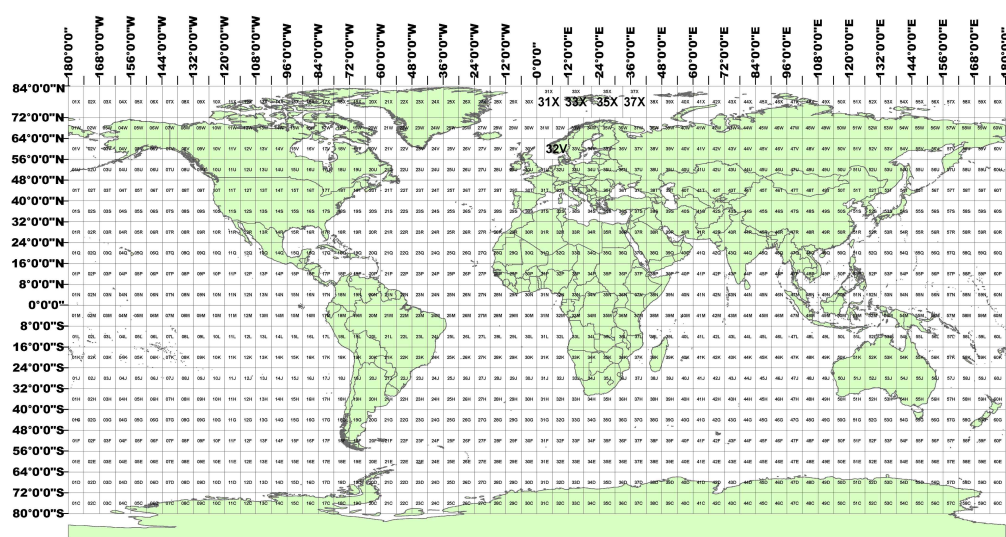
L30, S30 산출물의 QA 밴드 (Quality Assessment band)를 제작하기 위해 대기 보정한 Landsat-8 영상은 다중분광밴드와 열 밴드(Thermal band, band 10)에 임계치를 주어 구름 픽셀을 구분하는 LaSRC 알고리즘을 통해 구름 마스크링(cloud masking)을 수행하였으며, 눈 마스크링은 NDSL (Normalized Difference Snow Index)에서 경험적 임계치를 통해 구분하였다. Sentinel-2 영상은 열 밴드가 없어 LaSRC 알고리즘을 통한 구름 마스크링에 제한이 있음에 따라 열 밴드 대신 권운밴드(cirrus band)를 사용하여 구름 픽셀을 구분하는 Fmask (Function of Mask) 알고리즘을 통해 구름 마스크링을 수행한다. 본 과정을 통해 제작된 QA밴드는 다음 표 3-2와 같이 구성되어 있다.

<표 3-2> HLS 프로젝트 산출물 QA밴드 구성 클래스

BIT	Description	BIT	Description
0	Cirrus	4	Show/ice
1	Cloud	5	Water
2	Adjacent to cloud/shadow	6	Not used
3	Cloud shadow	7	

□ 영상 재배열

Sentinel-2영상은 3가지 공간해상도(10m, 20m, 60m)를 가지는데 S30 산출물이 Landsat화 되는 과정에서 Landsat-8과 동일한 30m로 영상 재배열(spatial resampling) 과정이 수행된다. 영상 재배열 방법은 Sentinel-2의 해상도에 따라 다르게 적용된다. 10m 해상도는 가지는 밴드는 단순평균 방법으로, 20m 해상도를 가지는 밴드는 가중평균(4/9, 2/9, 1/9)으로, 60m 해상도를 가지는 밴드는 복제 방법으로 수행된다. 30m 공간해상도를 가지는 L30, S30 산출물은 타일(tile)을 형태로 제공되는데 타일링 시스템(Tiling System)은 Sentinel-2 자료와 동일하다 (그림 3-3). 한 타일의 크기는 109.8km이며 UTM (Universal Transverse Mercator) 기반의 MGRS (Military Grid Reference System) 에서 파생된 명명규칙과 동일하다.



<그림 3-3> HLS프로젝트 타일링 시스템

□ BRDF 보정

동일 지역(지표물)에 대해 태양의 위치와 센서의 관측각도에 따라 반사율이 달라지며 이러한 각도에 대한 효과를 정규화하는 과정을 BRDF보정이라 한다. BRDF 보정을 위해서는 동일 지점에 대해 태양각과 관측각을 달리하여 얻어진 3개 이상의 반사율 값이 필요하며(이규성, 2019), HLS 산출물은 Roy *et al.* (2016)이 제안한 c-factor 기법을 적용하였으며 관측각은 Nadir로 설정된다. BRDF보정은 Red Edge 밴드와 해안/에어로졸 밴드(Coastal/aerosol), 권운 밴드 (Cirrus), 수증기 밴드(Water vapor)를 제외한 모든 밴드에 적용된다.

□ 밴드 대역폭 조정

Landsat-8과 Sentinel-2 간의 각 밴드 대역폭 차이에 따른 반사도 차이를 극복하기 위해 Landsat-8 밴드 대역을 기준으로 Sentinel-2 자료의 각 밴드 대역들을 선형회귀방정식에 의해 조정한다. 이때 조정하는 Sentinel-2 밴드는 Landsat-8와 동일한 구성 밴드만 조정하게 되며 다음 표 3-3은 Sentinel-2자료를 Landsat-8 대역에 맞추기 위한 계수를 나타낸다.

<표 3-3> 밴드 대역폭 조정을 위한 Sentinel-2A/B 계수

Band Name			Sentinel-2A		Sentinel-2B	
HLS	OLI	MSI	Slope	Offset	Slope	Offset
CA	1	1	0.9959	-0.0002	0.9959	-0.0002
Blue	2	2	0.9778	-0.004	0.9778	-0.004
Green	3	3	1.0053	-0.0009	1.0075	-0.0008
Red	4	4	0.9765	0.0009	0.9761	0.001
NIR	5	8A	0.9983	-0.0001	0.9966	0.000
SWIR1	6	11	0.9987	-0.0011	1.000	-0.0003
SWIR2	7	12	1.003	-0.0012	0.9867	0.0004

3. 국토위성과 타 지구관측위성 간 융합 활용을 위한 기술 조사

가. 차세대중형위성4호(농림위성) 주 활용기관의 추진 연구 업무

차세대중형위성 1단계 개발 사업을 통해 확보된 500kg급 표준 플랫폼 기술을 활용하여 차세대 중형위성 2단계에서 개발되는 위성은 총 3기(3호 우주과학·기술검증, 4호 농림위성(산림위성), 5호 수자원 위성)이다. 차세대중형위성 1, 2단계 개발 사업을 통해 개발되는 총 5기의 위성 중에서 국토위성과 농림위성은 광학센서로 이루어져 있어 향후 차세대중형위성군에서 우선적으로 융합 활용이 가능할 것으로 사료된다. 농림위성은 농림업분야의 위성영상 수요 및 공공서비스를 위해 차세대중형위성 2단계 개발사업으로 추진 중에 있으며 2025년 발사 예정이다. 농림위성 발사 전의 기반 조성 및 발사 후 효율적인 임무를 수행하기 위해 주 활용부처에서는 그에 필요한 인프라를 구축 중이며, 농림위성의 주 활용기관은 산림청 소속의 국립산림과학원과 농촌진흥청 소속의 국립농업과학원으로, 농업분야와 산림분야의 각 수요에 맞는 기술개발을 수행하고 있다.

농림위성은 국토위성과 달리 농작물 작황이나 산림자원 관측 등의 임무를 수행하기 위해 식생 특성을 파악하는데 효과적인 Red-Edge 밴드를 추가적으로 보유하고 있으며 3일 주기로 한반도 전 지역 촬영이 가능한 120km 관측폭과 5m의 공간해상도를 가지고 있다. 표 3-4는 국토위성과 농림위성의 제원을 비교한 표이다.

<표 3-4> 차세대중형위성군 제원 비교(국토위성, 농림위성)

구분	(1호/2호) 국토위성	(4호) 농림위성
목적	정밀 지상 관측	농작물 작황, 산림자원 관측 등
운용고도	500km	~900km
관측폭	12km	120km
밴드구성	Blue Green Red NIR Panchromatic	Blue Green Red Red-Edge NIR
공간해상도	0.5m(2m)	5m
재방문주기	4.6일(2기 운영 시)	1~3일
발사일	1호 : 2021.03.22. 2호 : 2022년 예정	2025년 예정
주 활용부처	국토교통부(국토지리정보원)	산림청(국립산림과학원) 농촌진흥청(국립농업과학원)

□ 농업분야

• 배경 및 필요성

농촌진흥청은 농림위성정보의 효율적인 활용을 위해 위성영상으로부터 현업에 직접 활용이 가능한 산출물을 도출하여 공급할 예정이다. 하지만 기존 농림위성 개발사업을 통해 산출된 기본 산출물인 표준영상은 농업부문 활용에 한계가 있어 그에 필요한 전처리와 활용기술을 개발하는 ‘농업위성정보활용센터 구축 사업’을 수행하고 있다. 본 사업에서 주요 연구개발 내용은 ① 농업위성정보 기반기술 및 소프트웨어 개발(전처리, 활용산출물 알고리즘 기술개발), ② 농업위성영상의 활용 시스템(수집·활용·가공·배포시스템) 개발, ③ 농업위성정보 활용기반 구축(활용 산출물 품질 관리 및 표준화 지원) 및 운영체계 개발로 구성되어 있다.

• 주요 연구개발 내용

(1) 농업위성정보 기반기술 및 소프트웨어 개발

‘농업위성정보 기반기술 및 소프트웨어 개발’ 부분에서는 정밀 대기보정 영상 생성 기술개발과 표면반사율 영상 및 활용산출물 생성 기술개발을 위해 6가지의 세부 연구내용으로 구성되어있다.

< 목표 성과 >

- 대기영향을 보정한 **정밀 대기보정 영상** 생성 기술 개발
- 농업적 활용을 위한 **표면반사율 영상** 및 다양한 **활용산출물 생성** 기술개발

① 정밀대기보정 기술 개발

농림위성에서 촬영·수신한 표준영상값(DN)을 농업위성영상용 복사보정 기술을 개발하여 영상의 신호값(DN) 및 복사휘도(Radiance)로부터 대기의 영향이 제거된 표면반사율을 도출할 수 있는 대기복사전달모델 및 대기보정기술을 개발하고, 그에 필요한 파라미터들의 수집방안을 설계하는 내용을 포함하고 있다.

② BRDF 보정기술 개발

태양의 위치와 센서의 관측 각도에 따라 반사율이 달라지는 효과를 보정해주기 위해 태양 및 센서의 각도, 식생 특성, 지형기복, 지표면 거칠기 특성 등을 고려한 표면반사도 보정기술 개발과 검증에 대한 내용을 포함하고 있다.

③ 일별 식생지수 제작 기술 개발

농업위성영상의 5개 분광밴드 특성을 이용하여 제작 가능한 식생지수를 제시하고 그에 대한 특성 분석을 통해 최적의 식생지수를 선정하여 일별 제작하는 알고리즘 개발내용을 포함하고 있다.

④ 주기별 합성 식생지수 제작 기술 개발

7일, 10일, 15일, 30일 등의 주기별 식생지수 생산을 위해 Maximum Value Composit 합성 방법을 비롯한 여러 합성 방법의 비교 분석하여 최적의 합성 방법 개발 및 식생지수 시계열 보정 기술개발을 포함하고 있다.

⑤ 식생지수 변이 제작 기술 개발

10일, 15일, 1개월 간격의 기준 식생지수 제작을 위해 타 위성영상(Landsat, SPOT, Sentinel, RapidEye)과의 공간해상도 및 분광해상도 유사성 분석을 수행하고, 제작한 기준 식생지수는 동일

시점의 새로 취득된 식생지수와의 변이 판단을 위한 최적 임계값 설정 방법 개발, 변이 표현을 위한 최적의 Color Table 선정 및 가시화 방법을 제시하는 내용을 포함하고 있다.

⑥ 융복합 기술개발 및 기술검증·보완

기존의 다중 센서 위성영상과 공간정보와의 융복합 기술 개발을 통해 식생지수 기반의 고부가가치 농업 주제도 생산을 위한 기술개발 및 농림위성 본격 운영 전 농림위성과 유사한 사양의 Sentinel-2와 RapidEye를 이용해 기 개발된 기술들을 검증하는 내용을 포함하고 있다.

(2) 농업위성정보 활용시스템 개발

‘농업위성정보 활용시스템 개발’ 부분에서는 농업위성정보 제공을 위한 처리 절차 자동화 시스템 개발을 위해서 3가지의 세부 연구내용으로 구성되어있다.

< 목표 성과 >

- 농업위성정보를 안정적으로 제공하기 위해 산출물 검색, 주문, 배포 등의 작업 자동화 할 수 있는 시스템 개발

① 농업위성정보 운영시스템 기본 설계 및 상세설계

농업위성정보활용센터(가칭)에서 농업위성정보를 수집, 처리, 산출물 생성, 저장, 관리, 배포 등의 운영을 하기위한 업무 프로세스 정의 및 시나리오 개발을 하고, 업무처리를 위한 각 운영 시스템들의 효율적인 시스템 구축을 위한 기본 설계(H/W, S/W, N/W), SW개발 방법론, 검증방법, 시범가동 및 정상운용 등을 포함한 연차별 개발방안을 제시하는 내용이다.

② 농업위성정보 운영시스템 구현

농업위성정보를 운영하기 위해 필요한 시스템(수집시스템, 활용시스템, 관리·서비스 시스템)을 구현하는 내용을 포함하고 있다.

③ 농업위성정보 운영시스템 연계·통합

앞서 설명한 농업위성정보 기반기술과제에서 개발된 소프트웨어와 농림위성의 전처리 기술 중 지형보정 기술 개발 역할을 추진 중인 산림청에서 개발한 소프트웨어를 농업위성정보 운영시스템 간의 연계·통합하는 내용을 포함하고 있다.

(3) 농업위성정보활용 기반구축지원 및 운영체계 개발

‘농업위성정보활용 기반구축지원 및 운영체계 개발’ 부분에서는 농업위성정보 활용을 위해서 필요한 기준, 지침, 규정들을 마련하고 기반기술과 시스템 간의 연계를 위해 2가지 세부 연구내용으로 구성되어 있다.

< 목표 성과 >

- 농업위성정보의 효율적인 활용을 위한 기준, 지침, 규정 마련
- 농업위성정보의 활용기반 구축을 위한 기반기술과 시스템 간의 연계지원

① 농업위성정보 활용 기반 운영 및 고도화 방안 수립

고해상도 위성영상 관리 및 처리에 대한 관계기관 업무 현황, 규정을 파악하고 농업위성 산출물 관리 및 품질 관리 확보방안을 수립하여 농업위성 활용 산출물의 표준체계(메타데이터, 품질관리, 제품사양서 등)를 마련하고자 한다. 이와 더불어 위성정보활용기반의 연간 운영계획(안)을 수립하고 위성정보 활용응용기술 고도화를 위한 로드맵(안)을 수립하는 내용이다.

② 농업위성정보활용 기반 기술 및 시스템 상세설계 지원

정밀대기보정 및 BRDF 보정 기술 검증을 위한 현장자료 수집 및 기술검증, 식생지수기반의 산출물 생산을 위한 시계열 현장자료 수집 및 기술검증, 융복합 산출물 제작을 위한 사전 제작 지원하는 내용이다.

• 활용계획

농업진흥청은 본 사업을 통해 농업분야에 위성 활용을 극대화하여 ① 현업에 이용할 수 있는 고품질 활용산출물 제공을 위한 기술을 개발하고자 한다. 이를 통해 기존 작황·재해 평가 시 목적(目測), 청취 위주의 평가에서 위성자료를 제공함으로써 ② 혁신적인 농업관측 정보제공 체계 구축과 더불어 농업 관련 재해 대응에 기여할 것으로 기대된다. 이에 따라 ③ 필요한 시설·장비(하드웨어 및 소프트웨어)를 구축하여 농림위성정보를 체계적으로 수집·생산·관리·공급을 위해 농업위성정보활용센터(가칭)의 기반을 구축하고자 한다. 따라서 농업위성정보활용센터 산출물에 따른 ④ 연구개발 과제 및 기획 연구 수행을 통해 전문 인력을 양성하고, 위성정보 응용산업 활성화 추진을 할 수 있을 것이라 사료된다.

□ 산림분야

• 배경 및 필요성

산림청은 산사태, 대형산불과 같은 산림재해가 빈번하게 발생함에 따른 인명 및 재산 피해가 급증함에 따라 산림재해를 조기에 발견하여 피해를 최소화하기 위해 산림 전용 위성의 개발이 필요하다 판단하였다. 산림 전용 위성영상을 이용한 상시 광역 모니터링을 위해 위성 전처리 기술 및 필요한 활용 산출물 알고리즘을 개발하는 ‘산림위성활용 기술개발 및 인프라구축 실행 계획(2020~2025)’을 수립하였다. 본 사업에서 주요 연구개발 내용은 ① 산림위성 기초기술 고도화, ② 산림위성 활용산출물 알고리즘 개발, ③ 산림빅데이터 수집 및 위성정보 융합 활용기술 개발, ④ 위성 및 산림 빅데이터 융합 차세대 서비스 개발로 구성되어 있다.

• 주요 연구개발 내용

(1) 산림위성 기초기술 고도화

< 목표 성과 >

- 지형기복이 심한 우리나라 산림에 특화된 정밀기하보정 기술 개발
- 대기보정 원천기술 확보를 통해 원활한 Level 3 산출물 생산 기반 확충
- L2 산출물 무중단 자동 생산 및 실시간 검증을 위한 품질관리 강화

‘산림위성 기초기술 고도화’ 부분에는 산림에 적합한 전처리 기술 개발을 위해 지상관측망 설치·운영 및 라이브러리를 구축 하고 산림 위성영상의 위치정확도 제고, 정량분석 정확도 제고를 위해 정밀기하보정(L1), 대기보정 기술개발(L1)하여 기본산출물(L2)을 제작하는 내용을 포함하고 있다. 또한, 산림분석의 효율성 제고를 위하여 분석준비데이터(ARD) 생산을 위해 다양한 시기, 다양한 센서들에서 취득되어 상이한 데이터를 상호 보정하는 기술을 개발하는 내용을 포함하고 있다.

(2) 산림위성 활용 산출물 알고리즘 개발

< 목표 성과 >

- 산림재해 상시모니터링을 통한 신속한 피해 감시 및 정확도 피해강도 분석
- 복한을 포함한 주기적인 한반도 산림자원 모니터링 및 산림자원 통계 산출
- 국민체감형 식물계절변화 분석 및 산림생태계 건강성 모니터링

‘산림위성 활용 산출물 알고리즘 개발’ 부분에는 산림의 3대 분야(산림재해, 산림자원, 산림건강성)에 대해 활용산출물 27종을 생산하는 알고리즘을 개발하는 내용을 포함하고 있다. 27종 활용산출물은 산림에서의 이상현상을 신속하게 탐지하고 산림생태계 모니터링을 통해 산불, 병해충 등 위험지역 관리복구 지원 기초자료로 활용하며, 북한을 포함한 한반도의 국가산림기본통계(임상, 바이오매스, 임목축적 등), 기후변화적응 대책 수립 지원 등을 하고자 한다.

(3) 산림빅데이터 수집 및 위성정보 융합 활용기술 개발

< 목표 성과 >

- 산악기상망, NFI 등 지상관측망과 드론, 타 위성영상 및 산림공간정보 등 다양한 산림 빅데이터를 융합 활용하여 고도화된 산림정책지원 서비스 개발

‘산림빅데이터 수집 및 위성정보 융합 활용기술 개발’ 부분에는 지상-드론-위성 관측망 운영을 통해 수집된 자료는 AI 기반 분석을 위한 학습 데이터셋으로 구축하고 패턴 및 질감 분석 기술 개발을 통해 산림분야의 주 관심 객체인 수목의 자동탐지, 분류 등 AI 기반 분석 기초기술 개발 내용을 포함하고 있다. 향후 적용 센서 확대(LiDAR, SAR, 초분광, 타 위성영상 등) 및 현장관측정보, 인문사회 정보(미디어, SNS 등)를 융합하여 빅데이터 분석 능력을 첨단화하고자 한다.

(4) 위성 및 산림 빅데이터 융합 차세대 서비스 개발

< 목표 성과 >

- 산림위성 L2, L3 및 산림 빅데이터와 융복합하여 산출된 고부가가치 데이터를 손쉽게 이용가능 하도록 사용자 친화적 서비스 제공

‘위성 및 산림 빅데이터 융합 차세대 서비스 개발’ 부분에는 위성산출물(기본 산출물, 활용 산출물) 및 산림 빅데이터를 정부기관(국가전산망)과 일반사용자(오픈플랫폼)로 구분하여 맞춤형 배포 서비스를 추진하고, 현업과 산림정책 의사결정을 위해 객관적인 근거자료 제공을 위한 산림정책 지원 서비스를 개발하는 내용을 포함하고 있다. 또한, 산림위성 사용자 그룹을 운영하여 사용자 유형을 고려한 국가산림정보위성센터 교육 프로그램 운영을 통해 사용자 저변을 확대하고자 한다.

- 활용계획

산림청은 본 사업을 통해 산림분야에 위성정보 활용 극대화를 위해 기초기술, 활용기술을 확보하고 산림 3대 분야(산림재해, 산림자원, 산림건강성)에 적합한 활용산출물을 개발하여 산림정책 실효성을 제고하고자 한다. 산림위성으로 축적되는 영상과 더불어 다양한 산림데이터의 효율적 활용을 위한 법적 근거를 마련하고, 지속 가능한 산림관리와 FAO, NASA, ESA 등 국제기관과의 위성영상 제공을 통한 국제 협력 강화 및 국가 위상 제고에 기여하고자 한다. 따라서 산림분야 수요기술 개발을 위해 연구개발 및 기획 연구 수행을 통해 농림위성 융합산업 창출 기반 및 민간위성 활용 시장 조성을 통해 전문 인력을 양성하고, 기술경쟁력 확보에 기여할 수 있을 것이라 사료된다.

다. KOMPSAT기반 융합 활용 리뷰

고해상도 국토위성과 유사한 스펙을 가진 KOMPSAT-3/3A 영상이 타 위성영상과 융합 활용을 위해 검토정한 기술 조사 및 융복합 활용한 사례를 통해 향후 국토위성이 타 위성과 융합 활용 시 고려되어야 할 사항 등을 도출하고자 한다.

<표 3-5> KOMPSAT 기반 교차검보정 및 타 센서와의 접목 사례 관련 문헌

저 자	년 도	제 목
안호용 등	2020	KOMPSAT-3와 Landsat-8의 시계열 융합활용을 위한 교차검보정
신정일 등	2018	KOMPSAT-3A 영상과 항공정사영상의 영상정합 성공률 향상 방법
정민영 등	2020	Planetscope 영상을 이용한 KOMPSAT-3/3A 영상의 기하품질 향상 방안 연구
박형준 등	2019	Google Map을 이용한 GCP칩의 품질 분석

□ KOMPSAT-3와 Landsat-8의 시계열 융합활용을 위한 교차검보정

안호용 등(2020)은 활용성 높은 Landsat-8영상과 KOMPSAT-3영상의 융합 활용을 위해 2년간 Libya-4 Site에서 취득된 위성영상들을 이용하여 위성 간 RSR(Relative Spectral Response) 차이를 보정하는 SBAF(Spectral Band Adjustment Factor) 적용 전과 후의 교차검보정 결과를 비교하였다. 그 결과, SBAF 적용 전에는 두 위성 간의 Blue, Green, Red 밴드에서 약 6%이내,

NIR 밴드에서 약 23%의 반사율 차이를 보였고 SBAF 적용 후에는 Blue, Green, Red 밴드에서 약 4%이내, NIR 밴드에서 약 6%의 반사율 차이로 NIR밴드에서 크게 개선된 것을 알 수 있었다. SBAF 적용효과는 Blue, Green 밴드보다 Red, NIR 밴드에서 높게 나타났으며 향후 교차검보정의 정확도를 높이기 위해 BRDF보정 및 지형보정에 대한 필요성을 제시하였다.

□ KOMPSAT-3A 영상과 항공정사영상의 영상정합 성공률 향상 방법

신정일 등(2018)은 KOMPSAT-3A 영상의 정밀기하보정을 위해 항공정사영상을 이용하여 제작한 지상기준점 칩 영상(GCP Chip)과 KOMPSAT-3 영상 간 정합 성공률을 높이기 위한 방법을 제시하였다. 이를 위해 KOMPSAT-3A 전정색 영상(Panchromatic), 다중분광영상, 융합 영상(Pan-sharpening)과 지상기준점 칩 영상 간 영상 정합을 수행하였다. 본 연구에서 영상 정합 방법은 대표적인 강도 기반 영상 정합 기법인 ZNCC(Zero Mean Normalized Cross Correlation)와 MI(Mutual Information)를 사용했다. 그 결과, 전정색 위성영상과 회색조 항공정사영상을 이용한 경우, 두 기법의 영상 정합 성공률이 각각 12%, 21%로 가장 낮게 나타났으며, 융합영상을 사용한 경우 두 기법의 영상 정합 성공률이 각각 43~47%, 40~51%의 범위로 가장 높게 나타났다. 따라서 항공정사영상으로 제작한 지상기준점 칩 영상을 사용하여 정밀기하보정을 수행할 경우 융합영상을 사용하는 것이 높은 영상 정합 성공률을 확보할 수 있다. 이는 항공정사영상과 유사한 분광특성과 해상도를 가지고 있기 때문으로 판단된다. 이와 더불어 영상 정합의 실패 원인으로는 영상 간 촬영시기, 계절차이, 기상 등임을 확인할 수 있었으며 향후 다양한 오정합의 원인 분석을 통해 그 영향을 최소화할 수 있는 방안에 대한 연구를 통해 정합 성공률을 향상시킬 필요성을 제시하였다.

□ PlanetScope 영상을 이용한 KOMPSAT-3/3A 영상의 기하품질 향상 방안 연구

정민영 등(2020)은 KOMPSAT-3/3A Level 1R영상의 기하품질을 향상시키기 위해 영상 수급이 원활한 PlanetScope 정사영상을 이용하여 PlanetScope와 KOMPSAT-3/3A 영상과의 정합점을 GCP로 사용하는 기하보정 방법을 제안하였다. 이를 위해 먼저 두 영상에 대표적인 특징점 기반 영상정합 기법인 SIFT(Scale Invariant Feature Transform) 기법을 적용하여 정합점을 추출하였다. 추출한 정합점은 GCP로 이용하여 RPC(Rational Polynomial Coefficient) 블럭조정 기법을 적용하여 기하보정영상을 생성하였다. 기하보정된 KOMPSAT-3/3A 영상은 수치지형도와 중첩한 결과, KOMPSAT-3는 다중분광 영상의 위치오차(RMSE, Root Mean Square

Error)가 6.62 화소에서 1.25화소로, KOMPSAT-3A는 7.03화소에서 1.66화소로 감소되어 영상의 기하품질이 향상됨을 확인하였다. 위성영상에서의 기하품질은 위성영상 산출물의 위치정확도와 연관되므로 위성영상 분석 시 필수적인 기하보정 과정에 GCP 취득 대안으로 PlanetScope 정사영상의 사용 가능성을 보여주었다.

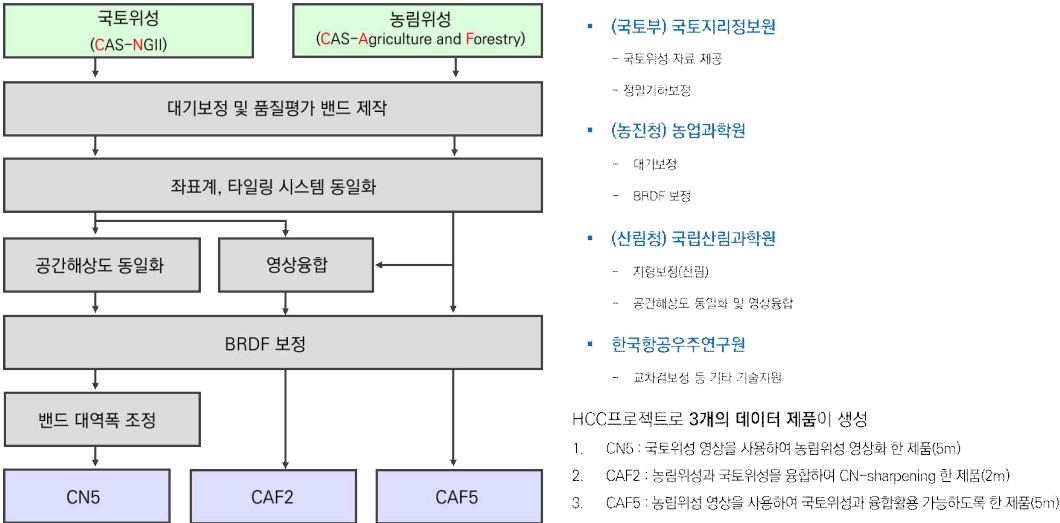
□ Google Map을 이용한 GCP칩의 품질 분석

박형준 등(2019)은 Google Map의 위성영상이 고해상도 위성영상의 대체 가능성을 판단하기 위해 KOMPSAT-3A 위성영상과 Google Map의 GCP Chip 정합 성능을 비교하였다. GCP Chip은 알고 있는 지상좌표에 영상의 중심에 설정하고 일정한 크기로 자른 영상조각을 의미한다(이계동 등, 2019). 본 연구에 사용된 GCP Chip은 국토위성의 정밀기하보정을 위해 구축된 남한지역의 GCP Chip을 사용하였으며, GCP Chip의 지상좌표는 통합기준점을, 영상은 국토지리정보원에서 구축한 항공정사영상을 이용하여 구축된 자료이다. Google Map의 위성영상과 GCP Chip 정합 성공률은 87%였으며, KOMPSAT-3A 위성영상과 GCP Chip 정합 성공률은 각각 89%로 유사한 정합 성공률을 보임에 따라 Google Map으로 고해상도 위성영상을 충분히 대체할 수 있다고 판단하였다. 또한, 정합에 실패한 GCP Chip의 주요 정합 실패 원인을 분석하였다. 분석 결과, 주요 실패 원인은 입력영상과 GCP Chip 간의 촬영 시기 차이, 촬영 각도의 차이가 있었으며 정밀한 기하보정을 위하여 주요 실패 원인인 촬영 시기, 촬영각도를 고려한 정합방법에 대한 개선방안 및 필요성을 제안하였다.

4. 결론 및 기대효과

본 연구는 국토위성영상의 융합 활용을 위한 기초연구 단계로서 융합 활용의 대표적인 사례인 HLS 프로젝트를 통해 프로젝트 참여 기관 간의 역할과 수행된 영상 처리방법, 최종 산출물을 검토하여 향후 국토위성이 타 지구관측위성들 간의 융합 활용 시 필요한 전처리 과정, 예상되는 한계점, 그에 대한 고려사항을 구상해볼 수 있었다. 또한 국토위성과 유사한 스펙을 가진 KOMPSAT-3A 영상이 타 지구관측위성과의 융합 활용을 위해 수행된 교차검보정 기술 조사를 통해 향후 국토위성이 타 지구관측위성영상 간의 융합 활용을 위해서 고려되어야 할 사항을 파악하였다. 이와 더불어 국토위성과 같이 광학 센서로 구성되어 있는 농림위성은 향후 차세대중형위성군에서 우선적으로 융합 활용이 가능할거라 사료됨에 따라 농림위성 활용기관의 연구사업 조사를 통해 각 위성센터들

간의 주 연구분야를 파악하였고, 융합활용을 위한 프로젝트 추진 시 프로젝트 참여기관의 역할분담에 각 위성센터들 간의 주 연구분야를 고려한 프로젝트를 구성할 수 있다.



<그림 3-4> HCC프로젝트 구상도(안)

구상한 프로젝트명은 HCC 프로젝트(Harmonized Compact Advanced Satellite(CAS) Constellation)로, 차세대중형위성군에서 광학센서를 탑재한 국토위성과 농림위성을 융합 활용하기 위한 프로젝트이다. 본 프로젝트는 관계부처(과기정통부, 국토부, 산림청, 농진청 등) 합동 연구 개발 사업이 필요하며 프로젝트 참여기관과 전체적인 영상처리 흐름도는 그림 3-4와 같다.

HCC프로젝트의 입력자료는 국토위성자료와 농림위성자료이며 본 구상도에서 국토위성은 CN(CAS-NGII)으로, 농림위성은 CAF(CAS-Agriculture and Forestry)로 표현하였다. 입력 자료는 3개의 산출물을 생성할 수 있으며, CN5, CAF2, CAF5이다. 산출물명 앞의 위성 약자는 주 입력영상을 의미하며 산출물 명 뒤에 번호는 각 산출물의 공간해상도를 의미한다. CN5는 국토 위성영상을 사용하여 농림위성 영상화한 산출물로 공간해상도 5m로 재생산된다. CAF2는 국토 위성의 다중분광영상(2m)과 농림위성의 다중분광영상(5m)을 영상융합한 제품으로, 농림위성영상을 2m 국토위성화 한 제품이다. CAF5는 농림위성영상을 이용하여 CN5와 융합 활용 가능하도록 한 제품이다. 국토위성과 농림위성의 자료를 이용하여 3개의 산출물을 제작하기 위해서는 그림 3-4와 같은 영상처리 과정이 크게 6가지로 구성되며 이때 각 영상처리 단계에서 프로젝트 참여 기관 간의 역할뿐만 아니라 자료 배포, 자료 규격 등 프로젝트 운영에 대한 역할 상세 조율 등 많은 검토가 필요하다.

본 결과는 향후 차세대중형위성군 내 광학센서 간 융합활용을 위해 초기자료로 타 위성자료와의 융합 활용에 적용 가능할 것으로 기대된다.

참고문헌

- 국립산림과학원 (2020), 산림위성활용 기술개발 및 인프라구축 실행계획(2020~2025)
- 농촌진흥청 (2021), 2021년 농촌진흥청 농업과학기술 연구개발사업 신규과제 RFP(농업위성 정보활용 기반구축지원 및 운영체계 개발)
- 농촌진흥청 (2021), 2021년 농촌진흥청 농업과학기술 연구개발사업 신규과제 RFP(농업위성 정보 기반기술 및 소프트웨어 개발)
- 농촌진흥청 (2021), 2021년 농촌진흥청 농업과학기술 연구개발사업 신규과제 RFP(농업위성 정보 활용시스템 개발)
- 박형준, 손종환, 신정일, 권기억, 김태정 (2019), Google Map 을 이용한 GCP 칩의 품질 분석, 대한원격탐사학회지, 제 35권, 6호, pp. 907~917.
- 산림청 (2020), 산림위성 개발 및 운영 기본계획(2020~2024)
- 신정일, 윤완상, 박형준, 오관영, 김태정 (2018), KOMPSAT-3A 영상과 항공정사영상의 영상정합 성공률 향상 방법, 대한원격탐사학회지, 제 34권, 6호, pp. 893~903.
- 안호용, 나상일, 박찬원, 홍석영, 소규호, 이경도 (2020), KOMPSAT-3와 Landsat-8의 시계열 융합활용을 위한 교차검보정, 대한원격탐사학회지, 제 36권, 6-2호, pp. 1523~1535.
- 안호용, 김계영, 이경도, 박찬원, 소규호, 나상일 (2018), 농업관측을 위한 KOMPSAT-3 위성의 Spectral Band Adjustment Factor 적용성 평가, 대한원격탐사학회지, 제 34권, 6-3호, pp. 1369~1382.
- 이규성 (2019), 육상 원격탐사에서 광학영상의 대기보정, 대한원격탐사학회지, 제 35권, 6-3호, pp. 1299~1312.
- 이제동, 윤종성 (2019), 특징점 추출기법을 이용한 접근불능지역의 위성영상 GCP 칩 자동추출, 한국측량학회지, 제 37권, 4호, pp. 211~218.
- 정민영, 강원빈, 송아람, 김용일 (2020), Planetscope 영상을 이용한 KOMPSAT-3/3A 영상의 기하품질 향상 방안 연구, 한국측량학회지, 제 38권, 4호, pp. 327~343.
- Claverie, M., Ju, J., Masek, J. G., Dungan, J. L., Vermote, E. F., Roger, J. C., Skakun, S. V., and Justice, C (2018), The Harmonized Landsat and Sentinel-2 surface reflectance data set. Remote sensing of environment, Vol. 219, pp.

145-161.

- Galvao, L. S., I. Vitorello, and R. Almerida (1999), Effects of band positioning and bandwidth NDVI(Normalized Difference Vegetation Index) measurements of tropical savannas, *Remote Sensing of Environment*, Vol. 67, pp. 181-193.
- Roy, D. P., Zhang, H. K., Ju, J., Gomez-Dans, J. L., Lewis, P. E., Schaaf, C. B., Sun, Q., Li, J., Huang, H., and Kovalskyy, V. (2016). A general method to normalize Landsat reflectance data to nadir BRDF adjusted reflectance. *Remote Sensing of Environment*, Vol. 176, pp. 255-271.

제4장

광학위성영상 구름 인덱스 맵 시범제작

1. 연구의 배경 및 목적
2. 연구 내용
3. 결론 및 기대효과

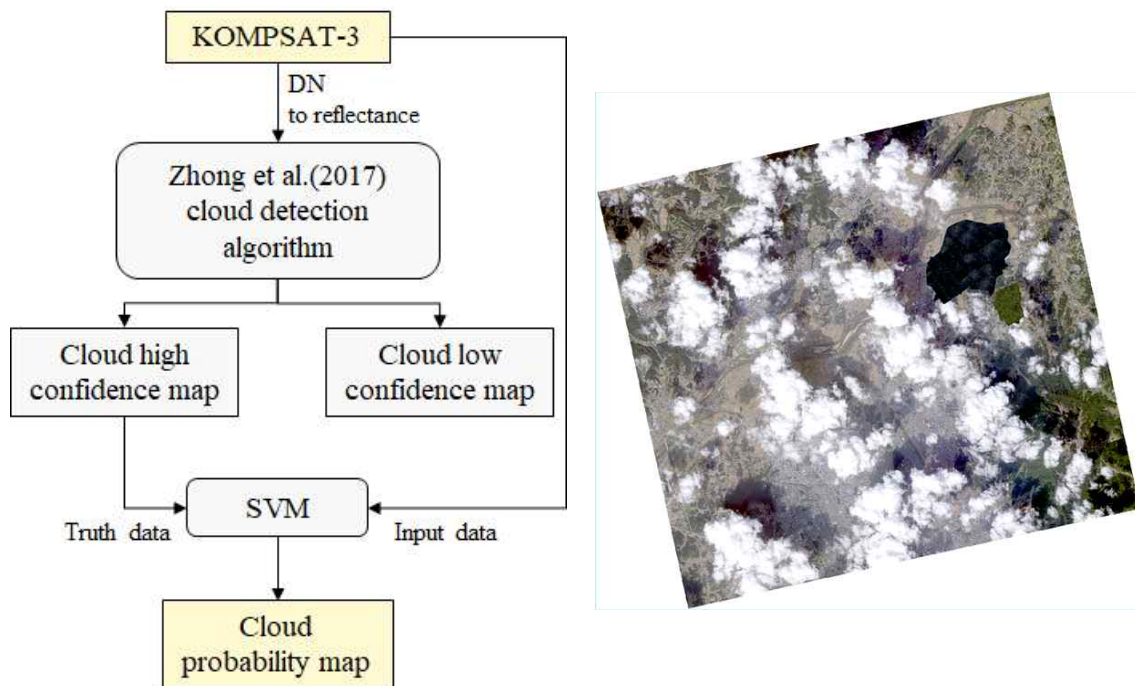
1. 연구의 배경 및 목적

광학위성영상에 함께 찍힌 구름은 사용자가 탐지하고자 하는 지표면의 관심 객체와 유사한 반사도를 갖고 있는 경우 방해 요소로 작용되므로 이를 미리 영상에서 제거한 후 사용하게 된다. 그러나 사용자가 직접 영상에서 구름을 제거하기 위해서는 복잡한 탐지 알고리즘을 적용하거나 수작업으로 제거하는 경우에는 오랜 시간이 소요되는 등의 어려움이 있다. 이를 위해 Landsat 위성은 영상과 함께 영상에 존재하는 구름 및 눈/얼음 등에 대한 픽셀정보를 함께 제공하고 있으며, Sentinel 위성은 구름에 대해 Dense/Cirrus로 나누어 벡터형태로 제공하고 있다. 이에 따라 사용자는 제공받은 구름의 인덱스 정보를 사용하여 목적에 따라 구름만을 탐지 또는 제거가 가능하며, 사용자의 쉬운 위성영상 활용이 가능하다. 따라서 위성영상의 활용성을 높이기 위해서는 위성영상과 함께 구름에 해당하는 픽셀에 대한 정보의 제공이 필요하다. 본 연구에서는 첫째, 국토위성에 적용 가능한 Zhong et al.(2017) 알고리즘을 이용해 구름을 탐지하여 인덱스 맵(binary)을 제작한다. 둘째, 인덱스 맵의 폭넓은 활용 가능성을 높이기 위해 SVM을 이용해 인덱스 맵을 확률도[0,1]로 제작한다. 더 나아가서, 대량으로 축적되는 위성영상의 구름 인덱스 맵 자동 제작을 위해 머신러닝/딥러닝 기반의 자동 제작 가능성을 검토한다.

2. 연구 내용

가. 연구 흐름 및 데이터

본 연구에서는 국토위성이 보유하고 있는 밴드(Visible, NIR)만으로 구름탐지가 가능한 Zhong et al.(2017)의 구름탐지 알고리즘을 적용한다. 국토위성 본격 운영은 시작되었으나('21.10.18.), 본 연구에 필요한 TOA reflectance 변환에 사용되는 파라미터 정보가 준비 중으로, 우선 KOMPSAT-3 영상을 활용하여 시범제작하고 향후 국토위성에 적용할 예정이다. 활용된 영상은 2019년 10월 19일 청주지역을 촬영한 영상으로, 적은 형태의 구름과 구름에 의한 그림자가 영상 전 영역에 걸쳐 분포하고 있다. 구름 인덱스 맵을 이진영상과 더불어 확률도[0,1]로 표현하기 위해 머신러닝 알고리즘 중 하나인 SVM(Support Vector Machine)을 활용한다. 이때 구름에 대한 참값(truth data)이 필요한데, Zhong et al.(2017) 알고리즘 적용을 통해 제작된 구름일 확률이 높은 픽셀을 나타내는 cloud with high confidence map을 참값으로 사용한다 (그림 4-1).



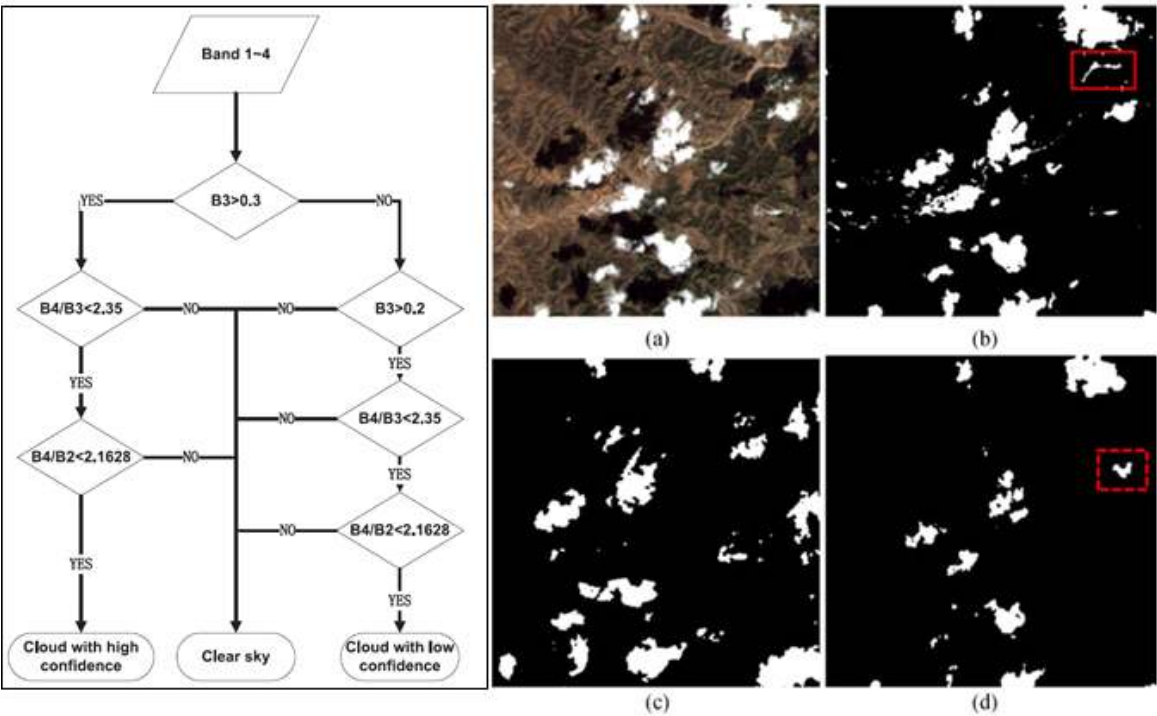
<그림 4-1> 연구 흐름도 및 데이터(KOMPSAT-3, 2019.10.19. 촬영)

나. Zhong et al.(2017) 구름탐지 알고리즘 적용

기존의 구름탐지 기법들은 구름의 분광 특성을 이용하여 설계되었다. 구름(cloud)이나 눈(snow)에 민감한 파장대역인 SWIR(Shortwave Infrared) band를 활용하거나, 구름의 온도가 주위 지표 온도보다 낮다는 특성을 바탕으로 TIR(Thermal Infrared) band를 활용하였다. 그러나 국토위성은 가시광선대역(Blue, Green, Red) 및 근적외선(Near Infrared)대역의 밴드를 갖고 있기 때문에 기존의 구름탐지 알고리즘을 적용하기에 어려움이 있다.

Zhong et al.(2017)은 SWIR band와 TIR band를 보유하고 있지 않은 중국의 Huan Jing 1(HJ-1)과 Gao Fen 1(GF-1) 위성의 구름 및 그림자를 탐지하기 위한 알고리즘을 제시하였다(그림 4-2). Landsat ETM+의 임계값 기반 구름탐지 알고리즘(ACCA)에서 가시광선대역과 근적외선 대역 밴드를 사용하는 부분만 활용한 것으로, 구름일 확률이 높은 픽셀인 cloud with high confidence map과 구름일 확률이 낮은 픽셀인 cloud with low confidence map, 청천영역 등이 생성된다. Cloud with high confidence map 제작을 위해 NIR과 Red 밴드비(B4/B3)를 통해 구름을 식생지역으로부터 분리한 후, NIR과 Green 밴드비(B4/B2)를 통해 나머지 영역을 토양과 식생활력도가 낮은 영역으로부터 분리하였다. 임계값 설정은 지표 물체의 방사특성을 기반으로 결정하였으며, 90% 이상의 탐지정확도를 보여주었다. 국토위성이 해당 중국위성과 보유 밴드 제원이 같아 적용 가능할 것으로 판단하며, 앞서 언급한 바와 같이 KOMPSAT-3 영상에 적용하여 국


토위성의 적용 가능성을 검증하고자 한다.




<그림 4-2> Zhong et al.(2017)의 구름탐지 알고리즘 및 탐지결과 예시, (a)True color(HJ-1), (b)Cloud map with low confidence, (c)Cloud-shadow map, (d)Cloud map with high confidence

1) 알고리즘 적용을 위한 주요 고려사항(1)

Zhong et al.(2017) 알고리즘을 적용하기 위해서는 적용하고자 하는 위성과 Landsat ETM+의 spectral response가 유사해야 한다. Zhong et al.(2017)이 제시한 알고리즘은 Landsat ETM+의 구름탐지 알고리즘에서 Blue, Green, Red, NIR 밴드만 사용한 부분을 활용한 것이므로 해당 알고리즘을 적용하기 위해서는 spectral response가 유사해야 한다는 전제조건이 있다. 아래 <그림 4-3>은 본 연구에 사용될 KOMPSAT-3(K3)의 spectral response를 나타내며, <그림 4-4>는 Zhong et al.(2017)에서 HJ-1과 GF-1 및 Landsat ETM+의 spectral response 비교 결과를 나타낸다. K3와 ETM+의 밴드별 spectral response는 유사성을 가지고 있는 것으로 보이므로 K3 영상에 해당 알고리즘의 적용이 가능한 것으로 판단된다. 추후 국토위성에 적용하기 위해서는 국토위성의 밴드별 spectral response 정보를 기반으로 ETM+와의 유사성을 판단해야 한다.



<그림 4-3> KOMPSAT-3의 spectral response(Yeom et al., 2018)



<그림 4-4> GF-1&HJ-1과 Landsat ETM+의 spectral response 비교(Zhong et al., 2017)

2) 알고리즘 적용을 위한 주요 고려사항(2)

Zhong et al.(2017) 알고리즘은 reflectance 값을 기반으로 임계값을 적용하고 있기 때문에 적용하고자 하는 위성영상의 DN 값을 TOA reflectance 값으로 변환하여 적용해야 한다. 상용 S/W 인 ENVI에서는 radiometric calibration 모듈을 이용해 DN 값에서 TOA reflectance 값으로의 변환을 제공하고 있지만, 본 연구에 사용될 K3 영상의 헤더파일에는 reflectance 변환에 필요한 매개변수를 제공하고 있지 않기 때문에 상용 S/W를 통한 자동 변환이 어렵다. 따라서 K3의 TOA reflectance 값을 얻기 위해 영상기반 대기보정을 수행하며, 이 중 수식에 필요한 변수를 구할 수 있는 AR(Apparent Reflectance) model을 사용하고자 한다 (식 (1)). 직접 변환하는 과정을 검증하기 위해 먼저 AR model을 이용해 직접 변환한 Landsat 8의 reflectance 값과, 상용 S/W를 통해 변환된 Landsat 8의 reflectance 값을 비교·검증하여 타당성을 도출한 뒤, K3 영상을 AR model에 적용하여 reflectance 변환을 수행하였다.


$$\rho_{\lambda} = \frac{\pi L_{\lambda} \cdot d^2}{ESUN_{\lambda} \cdot \cos \theta_s} \quad (1)$$

ρ_{λ} : TOA reflectance, L_{λ} : TOA spectral radiance($W \cdot m^{-2} \cdot sr^{-1}$), $ESUN_{\lambda}$: 평균태양복사조도(the average solar exoatmospheric spectral irradiance($W \cdot m^{-2} \cdot band^{-1}$), θ_s : sun zenith angle, d : the ratio of Earth Sun distance

3) 적용 결과


DN값을 reflectance 값으로 변환하기 위해 AR model을 사용하였다. 수식에 필요한 태양복사조도, 영상이 촬영된 날의 지구와 태양간의 거리 등의 정보를 Landsat의 경우 USGS 웹사이트에서, KOMPSAT의 경우 SIIS에서 제공하는 데이터 매뉴얼 또는 논문 등을 참고하였다. 먼저, Landsat8 영상을 이용해 ENVI S/W에서 제공하는 radiometric correction 모듈을 이용해 변환

한 reflectance 값과, 식 (1)을 이용해 변환한 값을 비교하였다. 그 결과, 유효숫자 소수점 이하 두 자리까지 일치하는 것을 확인하였으며, <그림 4-5>와 같이 Landsat 8 영상을 기반으로 구름인 영역과 구름의 가장자리 부분이 각각 cloud with high confidence map과 cloud with low confidence map에 잘 나타났다.



<그림 4-5> Landsat 8 적용 결과

이에 따라, 청주 지역을 촬영한 KOMPSAT-3 영상을 matlab을 이용해 reflectance로 직접 변환한 후, Zong et al.(2017) 알고리즘을 적용하여 cloud with high confidence map을 제작하였다 (그림 4-6). 영상에 존재하는 구름의 깊이가 깊고 형태가 뚜렷하여 cloud with high confidence map에서 대부분의 구름이 포함되었으나, 일부 아파트 벽면의 밝은 부분이나 흰색의 옥상을 가진 건물이 구름으로 함께 나타났다.




<그림 4-6> cloud with high confidence map(KOMPSAT-3 적용 결과)

다. 머신러닝(Machine learning) 기반 확률도 제작

구름 인덱스를 확률도[0,1]로 제공하게 되는 경우, 이진영상(binary)으로 제공했을 때 보다 사용자의 목적에 따라 임계값 적용을 통해 다양한 활용이 가능할 것으로 판단된다. 예를 들어 머신러닝/딥러닝 활용을 위해 구름에 대한 정확한 정보가 필요한 경우 임계값을 높게 잡아 사용할 수 있으며, 지표의 관심객체 탐지를 위해 구름의 제거가 필요한 경우 임계값을 낮게 잡아 구름 가장자리의 모호한 부분까지 제거하는데 사용할 수 있다. 이용석 외(2019)는 산림 층위구조(canopy) 분류를 위해 위성영상을 기반으로 확률도를 제작하였으며, 히스토그램에서 임계값 0.5를 설정하여 단층구조와 다층구조를 분류하였으며, 한국항공우주연구원(2015)은 식생유형을 나타내는 binary 자료를 바탕으로 해당 픽셀이 특정 식생 비오톱 유형에 속할 확률 값을 계산하였으며, 각 픽셀 당 최고 확률값을 가지는 유형으로 식생비오톱 주제도를 작성하였다. 이와 같이 본 연구에서는 구름탐지 결과를 확률도로 표현해주는 LIBSVM(Chang and Lin, 2011)을 활용하고자 한다. LIBSVM은 Chang and Lin(2011)에 의해 머신러닝 알고리즘 중 하나인 SVM을 오픈소스로 제공하는 Library로, matlab, python, R 등 다양한 형태로 제공하고 있다. 성능은 물론 지속적으로 업데이트 버전을 제공하고 있으며 상용 S/W 없이도 손쉽게 사용 가능하다는 장점이 있다. SVM 트레이닝을 위해서는 구름에 대한 정확한 정보가 필요한데, 이는 Zhong et al.(2017) 알고리즘 적용으로부터 제작된 cloud high confidence map을 활용하고자 한다.


1) SVM 적용 결과 - KOMPSAT-3(청주, 2019.10.19.)

SVM 트레이닝을 위해 사용되는 데이터가 정확할수록 분류 정확도도 높다. 앞서 제작된 cloud with high confidence map에는 구름 이외에도 건물에 대한 정보도 포함되어 있으므로 이를 제거하기 위해 median filter를 적용했다. 넓게 분포하고 있는 구름에 비해 건물의 크기는 매우 작기 때문에 이를 고려하여 window kernel은 11로 설정했다. cloud with high confidence map에 median filter 적용을 통해 구름 이외의 픽셀을 제거하고, 그림에도 제거되지 않은 부분은 육안판독을 통해 직접 제거하여 최종 구름에 해당되는 부분만을 트레이닝 데이터로 사용하였다. SVM을 통해 제작된 구름에 대한 확률도[0,1]는 <그림 4-7>과 같다.




<그림 4-7> SVM 결과 제작된 구름 확률도[0,1]

<그림 4-8>에서 (a)는 원영상, (b)는 SVM 결과로 얻은 이진영상, (c)는 SVM 결과로 얻은 확률도이다. 확률도에서 구름영역은 대부분 0.9 이상의 높은 확률 값을 가졌다. 그러나 우하단과 같이 건물의 옥상 또한 다소 높은 확률 값을 가진 결과도 보여주었다. 구름 탐지 결과를 이진결과가 아닌 확률도로 얻으면, <그림 4-8>과 <그림4-9>와 같이 구름의 가장자리나 얇은 구름 또한 값을 갖고 있기 때문에, 임계값을 주어 최대한 많은 구름에 대해 탐지할 수 있다는 장점이 있다.



<그림 4-8> SVM 결과 제작된 구름 확률도[0,1]




<그림 4-9> SVM 결과 제작된 구름 확률도[0,1]


2) SVM 기반 자동탐지 가능성 검토 결과

앞의 결과에서 트레이닝된 SVM 분류 모델을 다른 테스트영상에 적용함으로써 구름의 자동탐지 가능성을 검토하였다. 분류 모델의 트레이닝 과정은 훈련자료로 입력된 픽셀에 해당하는 값(반사도)을 이용하기 때문에, 분류 모델이 올바른 훈련자료로 트레이닝 되었다면 잘 분류된 결과가 도출될 것이다.


앞의 청주를 촬영한 K3영상으로부터 트레이닝 된 SVM 모델을 이용하여 새로운 영상에 적용하여 SVM 결과를 살펴보았다. 새로 사용된 영상은 2018년 10월 18일 밀양지역을 촬영한 KOMPSAT-3 영상으로 두꺼운 구름이 존재하는 영상이다. 훈련자료가 이미 앞에서 제작되어 있고, 모델 또한 이미 트레이닝되어 있기 때문에 훈련자료를 제작하는 과정과 모델 트레이닝에 소요되는 시간이 생략되어 결과를 보다 빠르게 얻을 수 있었다. <그림 4-10>은 K3영상과 기존에 트레이닝된 모델을 이용하여 얻은 확률도를 나타내며, 노란색 박스 영역을 확대하여 <그림 4-11>과 <그림 4-12>에 나타내었다. <그림 4-10>에서 구름에 해당하는 부분은 대부분 높은 확률 값을 가지지만 <그림 4-11>과 <그림 4-12>에서와 같이 주택지역을 따라 구름과 같이 0.9 이상의 높은 확률 값을 갖는 곳도 존재하였다.



<그림 4-10> (좌) KOMPSAT-3(밀양, 2018.10.18. 촬영), (우) 확률도



<그림 4-11> (좌) KOMPSAT-3(밀양, 2018.10.18. 촬영), (우) 확률도



<그림 4-12> (좌) KOMPSAT-3(밀양, 2018.10.18. 촬영), (우) 확률도

3) Landsat QA band와의 비교 결과


Landsat은 영상 내에 존재하는 구름, 구름에 의한 그림자, 얼음/눈, 폐색지역 등을 구분하여 16bit로 계산된 QA(Quality Assessment) band를 MSS, TM, ETM+, OLI/TIR까지 영상과 함께 제공한다 (<그림 4-13>). 사용자는 QA band를 활용하여 탐지 또는 제거 대상인 픽셀에 해당하는 값을 쉽게 추출할 수 있다.

Landsat 8 OLI, OLI/TIRS Collection 1 QA band bits; Read from RIGHT to LEFT, starting with Bit 0															
Cumulative Sum	65553	32767	16383	8191	4095	2047	1023	511	255	127	63	31	15	7	3
BIT	15	14	13	12	11	10	9	8	7	6	5	4	3	2	1
Description				Cirrus Confidence		Snow/Ice Confidence		Cloud Shadow Confidence		Cloud Confidence		Cloud	Radiometric Saturation		Terrain Occlusion
															Designated Fill

Landsat 8 OLI/TIRS Collection 1 Level-1 Quality Assessment Band Attribute and Pixel Value Possibilities	
Attribute	Pixel Value
Fill	1
Terrain Occlusion	2, 2722
Clear	2720, 2724, 2728, 2732
Radiometric Saturation - 1-2 bands	2724, 2756, 2804, 2980, 3012, 3748, 3780, 6820, 6852, 6900, 7076, 7108, 7844, 7876
Radiometric Saturation - 3-4 bands	2728, 2760, 2808, 2984, 3016, 3752, 3784, 6824, 6856, 6904, 7080, 7112, 7848, 7880
Radiometric Saturation - 5+ bands	2732, 2764, 2812, 2988, 3020, 3756, 3788, 6828, 6860, 6908, 7084, 7116, 7852, 7884
Cloud	2800, 2804, 2808, 2812, 6896, 6900, 6904, 6908
Cloud Confidence - Low	2720, 2722, 2724, 2728, 2732, 2976, 2980, 2984, 3744, 3748, 3752, 3756, 6816, 6820, 6824, 6828, 7072, 7076, 7080, 7084, 7840, 7844, 7848, 7852
Cloud Confidence - Medium	2752, 2756, 2760, 2764, 3008, 3012, 3016, 3020, 3776, 3780, 3784, 3788, 6848, 6852, 6856, 6860, 7104, 7108, 7112, 7116, 7872, 7876, 7880, 7884
Cloud Confidence - High	2800, 2804, 2808, 2812, 6896, 6900, 6904, 6908
Cloud Shadow - High	2976, 2980, 2984, 2988, 3008, 3012, 3016, 3020, 7072, 7076, 7080, 7084, 7104, 7108, 7112, 7116
Snow/Ice - High	3744, 3748, 3752, 3756, 3776, 3780, 3784, 3788, 7840, 7844, 7848, 7852, 7872, 7876, 7880, 7884
Cirrus Confidence - Low	2720, 2722, 2724, 2728, 2732, 2752, 2756, 2760, 2764, 2800, 2804, 2808, 2812, 2976, 2980, 2984, 2988, 3008, 3012, 3016, 3020, 3744, 3748, 3752, 3756, 3780, 3784, 3788
Cirrus Confidence - High	6816, 6820, 6824, 6828, 6848, 6852, 6856, 6860, 6896, 6900, 6904, 6908, 7072, 7076, 7080, 7084, 7104, 7108, 7112, 7116, 7840, 7844, 7848, 7852, 7872, 7876, 7880, 7884

<그림 4-13> Landsat OLI QA band 속성 값

앞에서 제시한 흐름에 따라, SVM에 Landsat OLI를 입력영상으로 하여 얻은 확률도의 결과와 Landsat에서 제공하는 QA band를 육안분석을 기반으로 비교하고자 한다. <그림 4-14>에서와 같이 QA band는 동일한 구름에 대해서도 세분화하여 표현하는 장점이 있지만, (d)와 같이 구름만을 제거하고 싶은 경우 구름에 해당하는 픽셀 값을 <그림 4-13>에서와 같이 다 찾아야 한다는 번거로움이 있다. 그러나 (b)와 같이 [0,1] 사이의 값으로 제공되는 경우 사용자는 육안판독을 통해 적절한 임계값을 주어 보다 간편하게 제거할 수 있다는 장점이 있지만, 구름으로 의심되는 부분임에도 0에 가까운 값을 가지는 구름의 경우 제거하기에 어렵다는 문제도 있다.



<그림 4-14> (a)Landsat OLI 영상 일부, (b)SVM 결과 확률도 (c)Landsat QA band
(d) QA band 일부 확대

라. 딥러닝(Deep learning) 기반 구름탐지 논문 리뷰

본 절에서는 구름 인덱스 맵의 자동 제작을 위해 광학영상의 딥러닝 기법 기반 구름 탐지 관련 논문을 살펴보고자 한다. 딥러닝에서는 정확하고 많은 양의 학습자료가 모델 성능에 주요한 영향을 미치기 때문에, 각 논문에서 사용한 테스트자료(test data)와 훈련자료(training data)의 구성을 중심으로 검토하였다.

성선경 외(2020)는 PlanetScope(4m, Visible/NIR) 영상의 구름 탐지를 위해 Deeplab V3+를 사용했다. 모델 트레이닝을 위해 Landsat 8(30m) 영상을 사용하였으며, 구름 참조자료는 USGS에서 제공하는 QA영상을 사용하였다. QA영상은 No data, 구름 그림자, 맑음, 얇은 구름, 구름 5개의 클래스로 제공하고 있고, 이를 구름과 구름 없음의 두 개 클래스로 재구성하고 영상을 512*512(pixel) 크기로 재구성하여 총 4,032개의 영상 패치로 사용하였다. 모델 테스트를 위해 사용된 PlanetScope 영상은 TOA reflectance 값으로 변환하여 사용되었고, 탐지 결과의 검증을 위한 PlanetScope 참조자료는 육안판독을 통해 제작하였다.

Jeppesen(2019)과 강종구 외(2021)는 USGS에서 제공되는 SPARCS(Spatial Procedure for

Automated Removal of Cloud and Shadow) Cloud Dataset을 이용해 모델을 훈련시켰다. 해당 데이터는 2013년에서 2014년 사이에 촬영된 Landsat 8 영상을 무작위로 선택하여 SWIR-NIR-Red 밴드의 위색영상(Pseudo image)을 제작한 후, 수작업을 통해 구름에 대한 라벨링을 생성한 데이터셋으로 512*512(pixel) 크기를 갖는다. 모델 테스트를 위해 사용한 Landsat 8 영상은 TOA reflectance 값으로 변환한 후, 반사도를 0과 1사이로 정규화하여 사용하였다. Jeppesen(2019)은 U-Net을 기반으로 탐지 정확도를 개선시킨 RS-Net을 사용하였으며, 강종구 외(2021)는 U-Net을 사용하였다.

Li et al.(2021)은 GF-1(8m, Visible, NIR) 영상의 구름 탐지를 위해 CNN을 개선한 SFRS-Net(A spatial folding-unfolding remote-sensing network)을 사용하였다. 모델 트레이닝을 위해 총 10,630 장의 GF-1 true color(RGB) 영상 중 약 70%를 사용하였으며, 영상은 512*512(pixel) 크기로 재구성 되어 육안분석을 통해 구름영역을 라벨링 하였다. 특히, 트레이닝을 위해서는 훈련자료를 시계방향으로 90도, 180도, 270도씩 회전하여 증가시켜 사용하였다.

향후 딥러닝 기반 구름을 탐지하기 위해 필요한 훈련자료의 경우 육안분석 기반 직접 제작 또는 무상으로 제공되고 있는 Landsat QA밴드, SPARCS Cloud dataset 등을 활용할 수 있으며, 데이터 증강기법(Augmentation)을 통해 훈련자료의 양을 증가시켜 사용할 수 있다.

3. 결론 및 기대효과

본 연구에서는 사용자의 편리를 위해 위성영상의 구름을 탐지하고 구름 인덱스 맵을 제작하였다. 인덱스 맵은 구름탐지 결과를 통해 이진형태(binary)로 제작되고, 사용자의 다양한 활용을 위해 SVM을 통해 확률도[0, 1]로 제작되었다. 국토위성은 가시광선 대역과 근적외선 대역의 밴드만을 보유하고 있기 때문에, 기존의 SWIR이나 TIR 밴드를 활용한 구름탐지 알고리즘 적용에 어려움이 있다. 이에 따라, 가시광선 대역 및 근적외선 대역만을 이용하여 HJ-1과 GF-1 위성영상의 구름탐지 알고리즘을 제안한 Zhong et al.(2017)의 알고리즘을 적용하여 구름 인덱스 맵을 제작하였다. 제작된 구름탐지 결과를 SVM의 참값으로 사용하여 구름에 대한 인덱스를 확률도[0, 1]로 제작하였다.

Landsat이나 Sentinel의 경우 구름에 대한 픽셀정보를 이진형태로 제공하고 있어 단순한 편리성이 있는 장점이 있는 반면, 구름의 가장자리 정보는 구름의 두께가 얇기 때문에 구름인지에 대한 사용자의 주관적인 판단이 애매하다는 단점이 있다. 국토위성은 구름에 해당하는 픽셀정보를 확률도[0, 1]로 제공한다면 사용자의 활용 목적에 따라 임계값 적용이 가능해 다양한 활용이 가능한 장점이 있을 것으로 기대한다. 또한 영상의 품질을 나타내는 윤량 등급을 나타낼 때 정의 한 기준에 따라 임계값을 적용하여 등급화가 용이할 것으로 판단된다.

구름인덱스 맵 제작을 위해 딥러닝을 활용하는 경우, 구름탐지에 효과적인 SWIR 및 TIR 밴드를 보유하지 않은 위성영상도 구름탐지가 가능한 장점이 있으며, 또한 이미 트레이닝 된 모델을 활용하여 자동 제작이 가능하다는 장점이 있을 것으로 기대된다.

참고문헌

- 한국항공우주연구원(2015), 위성정보공공활용사업 보고서
- 강종구, 김근아, 정예민, 김서연, 윤유정, 조수빈, & 이양원. (2021). Landsat 8 기반 SPARCS 데이터셋을 이용한 U-Net 구름탐지. 대한원격탐사학회지, 37(5), 1149-1161.
- 성선경, 최석근, & 최재완. (2020). 전이학습을 활용한 Deeplab-V3+ 모델 기반 PlanetScope 영상의 구름탐지. 대한공간정보학회지, 28(4), 25-32.
- 이용석, 백원경, & 정형섭. (2019). 광학 및 레이더 위성영상으로부터 인공신경망을 이용한 공주시 산림의 층위구조 분류. 대한원격탐사학회지, 35(3), 447-455.
- Chang, C. C., & Lin, C. J. (2011). LIBSVM: a library for support vector machines. ACM transactions on intelligent systems and technology (TIST), 2(3), 1-27.
- Jeppesen, J. H., Jacobsen, R. H., Inceoglu, F., & Toftegaard, T. S. (2019). A cloud detection algorithm for satellite imagery based on deep learning. Remote sensing of environment, 229, 247-259.
- Li, X., Zheng, H., Han, C., Zheng, W., Chen, H., Jing, Y., & Dong, K. (2021). SFRS-Net: A Cloud-Detection Method Based on Deep Convolutional Neural Networks for GF-1 Remote-Sensing Images. Remote Sensing, 13(15), 2910.
- Yeom, J. M., Ko, J., Hwang, J., Lee, C. S., Choi, C. U., & Jeong, S. (2018). Updating absolute radiometric characteristics for KOMPSAT-3 and KOMPSAT-3A multispectral imaging sensors using well-characterized pseudo-invariant tarps and microtops II. Remote Sensing, 10(5), 697.
- Zhong, B., Chen, W., Wu, S., Hu, L., Luo, X., & Liu, Q. (2017). A cloud detection method based on relationship between objects of cloud and cloud-shadow for Chinese moderate to high resolution satellite imagery. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 10(11), 4898-4908.

제5장

위성영상 사용 편의성 제고를 위한 그림자 추출 알고리즘 성능 비교

1. 연구의 배경 및 목적
2. 주요 내용
3. 국토위성 시범적용 결과
4. 결론

1. 연구의 배경 및 목적

고해상도 위성영상은 지표면의 많은 정보 목록(다양한 종류의 객체)을 포함하고 있어 도로와 건물 등을 추출하는데 많이 사용되고 있으나 기하학적인 오차와 노이즈 정보에 의해 객체를 추출하고 변화를 탐지하는데 어려움이 많다. 특히, 높은 건물들이 밀집되어 있는 도심 지역에서는 도로와 건물을 탐지하고 구분하는데 그림자가 방해요소로 작용하며, 그림자는 분광 특성이 수계와 유사하여 그림자와 수계를 분리하는데 애로 사항으로 나타나고 있다.

과거에는 중·저해상도 위성영상에서의 구름 또는 지형에 의한 그림자를 탐지하고 복원하는 연구가 많이 진행된 반면, 최근에는 고해상도 위성/항공 영상이 가용해짐에 따라 고해상도 영상에서 건물 등 지형지물에 의한 그림자 탐지에 관심이 많아졌다(Mostafa 등, 2017). 그림자 탐지 알고리즘은 크게 속성기반과 물리적 모델기반으로 구분되며, 속성기반은 임계값 설정, 불변 색채 공간(invariant color space), 감독/무감독 분류, 객체분할 등의 알고리즘을 포함한다. 물리적 모델기반은 태양 고도각, 방위각, 물체의 높이 등 기하학적 특성을 이용해 그림자 위치 및 크기를 결정하는 방법이다.


본 연구에서는 위성영상에서 원하는 객체를 추출하는데 있어 불필요한 그림자 정보를 제거하고 객체 탐지 정확도를 향상시키는 그림자 탐지 알고리즘을 탐색·검증하고자 한다. 이를 위해 속성기반의 그림자 탐지 알고리즘 중에서 국토위성에 적용 가능한 5가지 알고리즘을 선정하고 모의영상(K3A)에 적용하여 그 정확도를 확인하고자 한다.

2. 주요 내용

가. 그림자 추출 알고리즘

그림자는 빛이 지나가는 경로 위에 물체가 있을 때, 물체 뒤쪽에서 빛이 통과하지 못해 생기는 어두운 부분을 말한다. 그림자는 크게 Self Shadow와 Cast Shadow로 분류되는데, 아래 그림과 같이 물체 자체에 생기는 그림자를 Self Shadow라 하고, 물체가 빛을 가려 그림자가 지면에 생기는 것을 Cast Shadow라고 한다(Zhang 등, 2014). 다시 Cast Shadow는 물체에 가로막혀 전혀 빛을 받지 못하는 부분인과 빛이 부분적으로 도달하여 흐릿한 그림자인 Penumbra로 분류할 수 있

다. 본 연구에서는 위성영상에서 관측된 Cast Shadow를 탐지하고자 한다.



<그림 5-1> 그림자 정의(Zhang 등, 2014)

그림자 탐지 알고리즘은 태양고도각, 센서고도, 촬영각 등에 기반한 물리적 모델기반과 위성영상에서 관측된 그림자의 속성기반 모형으로 구분된다. 물리적 모델기반의 경우 정확한 영역에 대해 계산할 수 있지만, 위성영상 획득 시 마다 변화하는 기하 값과 촬영지역의 모든 객체에 대한 높이 값의 정확한 값이 요구되며 계산량이 많다는 단점이 있다(Jiang 등 2013). 본 연구의 목적은 사용자 친화형 영상 제품을 제공하기 위해 국토위성 영상의 그림자 픽셀정보를 추출하는 것으로, 촬영 당시 환경(태양 고도, 객체 높이, 촬영 각 등)에 영향을 받지 않고 그림자를 탐지할 수 있는 속성기반 모형을 우선적으로 검토할 예정이다.

속성기반 모형은 불변색체공간(Invariant color spaces), 밴드조합(Band math), 주성분(Principal component) 분석, 딥러닝 기반 등이 있으며, 불변색체공간과 밴드조합 기반의 알고리즘이 가장 보편적으로 사용되고 있다(Fu 등, 2020, Fang 등 2019, Han 등 2020).

아래 표 6-1은 본 연구에서 사용한 속성기반 그림자 추출 알고리즘으로 Shadow Index(SI), Object-based Shadow Index(OSI)는 밴드조합 기반, Normalized Saturation-Value Difference Index(NSVDI), Normalized-difference Shadow Index(NSI)는 불변색체공간 기반, Logarithmic Shadow Index(LSI)는 밴드조합과 불변색체공간 기반의 알고리즘이며 모두 국

토위성 밴드(R, G, B, NIR)를 이용하여 계산이 가능하다. SI(Sirmacek 등, 2008)은 항공사진으로 부터 건물을 탐지하는 기술의 정확도를 높이기 위해 Blue, Green 밴드를 이용하여 그림자를 우선 제거하여 사용하였으며, 이후 해당 식은 Benarchid 등(2013), 정세정 등(2020) 등 건물객체 추출 전 그림자 제거를 위해 많이 사용되고 있다. OSI(Fu 등, 2020)은 비교적 최근에 개발된 알고리즘으로 고해상도 영상에서 그림자를 분리하기 위해 우선 영상 내 그림자 강도를 추정하고 그림자와 분광특성이 유사한 수계를 구분하는 정규수분지수(NDWI) 값을 이용한 그림자 추출 알고리즘으로 그림자와 수계를 구분할 수 있는 장점을 가지고 있다. NSVDI(Ma 등, 2008)은 고해상도 위성으로 부터 도심지의 그림자를 추출하기 위해 RGB영상을 HSV로 변환하여 채도(Saturation)와 명도(Value) 값을 이용한 그림자 지수이며, 지수의 값이 0보다 큰 경우 그림자, 0보다 작은 값은 건물이나 도로, 식생은 0과 유사한 값으로 분포하여 쉽게 그림자를 분리할 수 있다는 장점을 가지고 있다. NSI(Fang 등, 2019)는 근적외선을 기반으로 하는 그림자 추출 지수로 Worldview-2, TripleSat-2, RapidEye 영상의 도심지를 대상으로 검증이 수행되었으며 우수한 탐지 정확도를 보였다. LSI(Han 등, 2020)는 HSV로 변환된 값과 강도(Intensity) 및 밴드의 분광특성을 기반으로 설계된 지수로 log 연산을 이용해 그림자와 그림자 외 영역에 해당하는 값의 차이를 확대하였다. LSI는 그림자를 탐지하는 여러 지수에 비해 더 높은 지형그림자 추출 성능을 보인다는 연구결과(Han 등, 2020)가 있으나 어두운 영역에서는 오탐지 발생가능성을 고려하여야 한다.

<표 5-1> 그림자 탐지 알고리즘

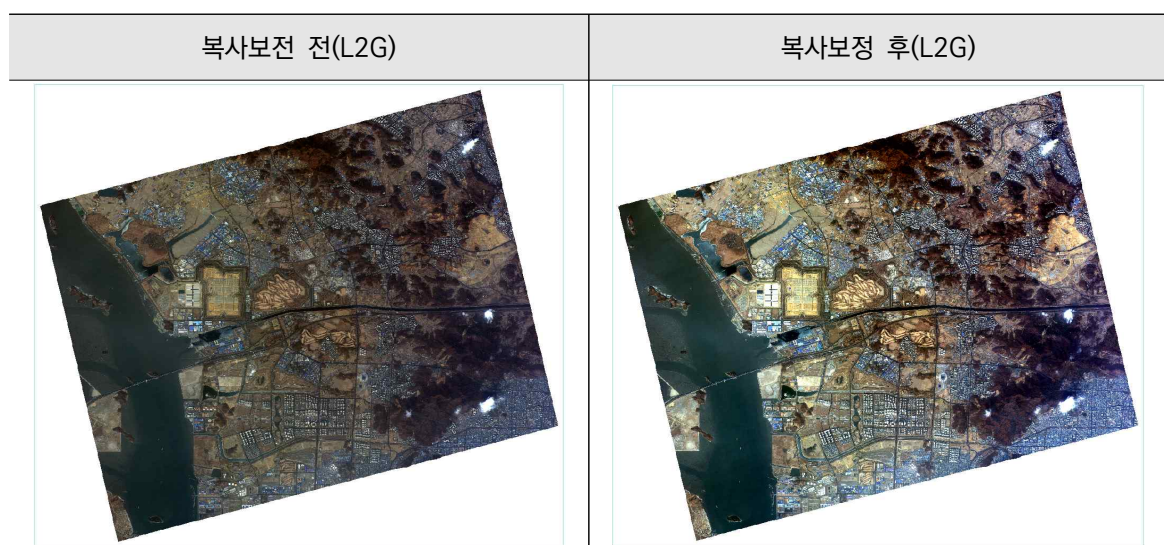
알고리즘	계산식
① SI Shadow Index	$= \frac{4}{\pi} \arctan \left(\frac{B-G}{B+G} \right)$
② OSI Object-based Shadow Index	$= \begin{cases} \left(1 - \frac{\sum_{i=1}^n band_i}{n}\right) - NIR, & \text{if } NIR \geq (r \times NDWI) \\ \left(1 - \frac{\sum_{i=1}^n band_i}{n}\right) - NDWI^{\frac{1}{3}}, & \text{else} \end{cases}$ * $r = (V_{sf} - V_s)/V_s$
③ NSVDI Normalized Saturation-Value Difference Index	$= \frac{Saturation_{i,j} - Value_{i,j}}{Saturation_{i,j} + Value_{i,j}}$
④ NSI Normalized- Difference Shadow Index	$= \frac{Saturation_{i,j} - NIR2_{i,j}}{Saturation_{i,j} + NIR2_{i,j}}$ * $NIR2 = NIR$ after a linear stretch of 2%
⑤ LSI Logarithmic Shadow Index	$= \ln \left(NIR \times \frac{Intensity_{i,j} - Hue_{i,j}}{Intensity_{i,j} + Hue_{i,j}} + 1 \right)$ * $Intensity = Value = (R+G+B)/3$

나. 실험 자료


국토위성센터는 항공우주연구원으로부터 표준영상(L1R)을 수신해 정밀기하보정, 정밀정사보정 처리를 한 L2G 영상을 생성한다. 그림자 탐지 알고리즘 적용에 앞서 상용 소프트웨어(ENVI)에서 제공하는 복사보정(Radiometric Calibration) Toolbox를 이용하여 L2G 영상에 복사보정을 수행하였다. 다만, ENVI에서 현재 국토위성센터에서 제공하는 Auxiliary 파일을 이용해 L2G Pan-sharpened 영상의 복사보정을 시도하는 경우, 일부 파라미터가 포함되지 않는 등의 문제로 보정이 수행되지 않는다. 따라서 본 연구에서는 아래와 같이 Auxiliary 파일의 몇 가지 정보를 수정한 후 진행하였다.

□ ENVI 복사보정 사용을 위한 *.aux 파일 수정사항

- PS(Pan-Sharpned) 밴드만을 위한 Auxiliary 파일 생성
- PS정보 내 offset 값을 MS에서 복사하여 사용
- ImagingStartLineTime, ImagingCenterLineTime, ImagingEndLineTime, Elevation, OffNadir, CollectedGSD 값을 PAN의 정보에서 복사하여 사용
- ImageColor 명칭의 변경(예 : Pan-Sharpned Blue → Blue)



<그림 5-2> 그림자 추출에 사용된 Kompsat-3A 영상('18.2.14)



<그림 5-3> 건물그림자 추출 관심영역 및 성능 평가 영역(빨간색 박스)

그림 5-2은 본 연구에서 사용된 Kompsat-3A 위성의 L2G 영상(좌: 복사보정 전, 우: 복사보정 후)으로 2018년 2월 14일에 촬영된 인천 지역의 영상이다. 이 중 건물 그림자의 추출을 위해 청라 국제도시 부근을 관심영역(그림 5-3)으로 정의하였으며, 이 지역은 청라호수공원을 포함하고 있어 그림자와 유사한 분광특성을 가지는 수계 영역과의 분리정확도도 함께 확인할 수 있어 선정하였다. 선정된 영역에 대해 위에서 설명한 5가지의 그림자 탐지 알고리즘을 적용하였으며, 이후 Otsu 알고리즘을 적용하여 임계값을 설정하고 영상을 이진화하였다. 그림 5-3의 빨간색 박스는 이진화된 영상의 성능 평가에 사용한 영역으로 그림자 영역과 그 외 영역의 비율이 유사하도록 건물 밀집지역으로 선정하여 수행하였다.

다. 성능 평가 방안

그림자 탐지 알고리즘의 성능은 재현율(Recall), 정밀도(Precision), F1-Score로 평가하였다. 식 6-1 ~ 6-3은 각각 재현율, 정밀도, F1-Score를 나타내며, TP(True Positive)는 실제 값과 예


측 값이 모두 참인 분류, FN(False Negative)는 실제 값은 참이나 예측 값은 거짓인 분류, FP(False Positive)는 실제 값은 거짓이나 예측 값이 참인 분류를 말한다. 따라서 재현율은 검증 데이터가 그림자인 영역에서 알고리즘이 그림자로 분류한 정확도를, 정밀도는 그림자라고 분류한 영역에서 검증데이터가 그림자인 영역의 정확도를 나타내며, F1-Score는 재현율과 정밀도의 조화 평균을 나타낸다.

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad \langle \text{식 6-1} \rangle$$

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}) \quad \langle \text{식 6-2} \rangle$$

$$\text{F1-Score} = 2 \times (\text{Recall} \times \text{Precision}) / (\text{Recall} + \text{Precision}) \quad \langle \text{식 6-3} \rangle$$

그림자 탐지 알고리즘의 성능 평가를 위해 건물 그림자를 수동으로 추출하여 참값으로 사용하였다. 그림 5-4(a)의 노란색 영역은 수동 추출한 그림자 영역을 보여주며, 그림 5-4(b)는 그림자 영역의 값을 1(참)로, 그 외의 영역을 0(거짓)으로 이진화한 결과이다.



<그림 5-4> (a) 수동 추출 결과(노란색 영역), (b) 이진화 결과(흰색 : 건물 그림자 영역, 검은색 : 그 외 영역)


라. 실험결과

그림 5-5(a)는 그림자 탐지 알고리즘의 적용 결과이다. 그림자 탐지 알고리즘의 적용 결과 다른 알고리즘에 비해 NSI와 OSI의 색대비가 뚜렷한 것을 볼 수 있다. 좌측 호수인 수계의 경우 밝은 색으로, 우측 건물 밀집지역에서 건물은 어두운 색을 띄며 그림자가 그 중간인 회색 영역으로 구분되었다. 특히나 NSI 알고리즘의 적용 결과 건물주변에서 그림자와 건물의 색 대비가 뚜렷해 육안상 구분이 용이하였다. OSI 적용 결과에서는 다른 알고리즘에 비해 좌측의 수계 부분이 가장 밝게 구분되는 것으로 보아 알고리즘의 주요 장점인 수계 분리 가능성을 확인할 수 있었다. SI 알고리즘과 NSVDI 알고리즘에서는 그림자의 영역이 건물과 다른 밝기를 가지는 것은 확인하였으나 수계와 유사한 밝기를 보여 임계값을 이용한 그림자 분리는 어려울 것으로 보인다. 한편 LSI 알고리즘은 log 연산을 통해 높은 성능을 보일 것으로 기대한 것과는 달리 그림자와 도로의 경계를 구분하기 어려웠다. 그림 5-5 두 번째 열(b)은 그림 5-5(a)에 Otsu 임계값 자동 추정 알고리즘(Otsu 1979) 적용하여 이진화 한 결과를 보여준다. Otsu 알고리즘은 다봉분포를 보이는 영상의 임계값을 자동으로 계산하는데 가장 보편적인 알고리즘으로 그림자 탐지 알고리즘 결과 모든 영상에서 다봉분포를 가지는 것을 확인하여 적용해보았다. 이진화 결과 그림자와 함께 수계, 도로가 포함되어 있는 것을 확인할 수 있는데, 모든 알고리즘에서 그림자의 밝기 값이 가장 밝은 수계와 가장 어두운 건물의 사이에 분포해 있기 때문인 것으로 사료된다. 향후 그림자만을 추출하기 위해 수계, 도로 영역의 객체 분리를 위한 전처리와 함께 이진화 알고리즘의 개선이 필요하다.

표 5-2는 검증데이터를 이용한 성능평가 결과이다. 모든 알고리즘에서 재현율이 0.93이상의 높은 값을 보여주는 데 이는 그림자로 분류된 픽셀이 많아서 높게 나타나는 것으로 판단된다. 정밀도와 F1-Score 값으로 보아, 육안으로 판단한 것과 마찬가지로 NSI가 가장 성능이 좋았고 OSI가 그 뒤를 이었다.

<표 5-2> 알고리즘 별 그림자 탐지 성능 결과

알고리즘	SI	OSI	NSVDI	NSI	LSI
재현율	0.9717	0.9752	0.9748	0.9335	0.977
정밀도	0.3619	0.4944	0.3861	0.5763	0.3309
F1-Score	0.5274	0.6561	0.5531	0.7126	0.4943




<그림 5-5> (a) 알고리즘 적용 결과, (b) 이진화 결과

3. 국토위성 시범 적용 결과

국토위성이 지난 2021년 10월 18일부터 본격 운영됨에 따라 한반도에서 촬영한 영상이 확보되고 있다. 본 연구에서 비교된 알고리즘이 국토위성에서도 유사한 성능을 보이는지 확인하기 위해 시범 적용하여 육안 분석을 수행하였다. 다만 국토위성은 아직 절대복사보정계수가 확보되지 않은 관계로 복사보정은 생략 후 DN값에 대해 적용하였으며, 그림자 영역에 대한 수동 추출 결과가 없어 정량적 성능평가는 수행하지 못하였다. 향후 절대복사보정 계수를 확보하고 그림자 영역의 수동

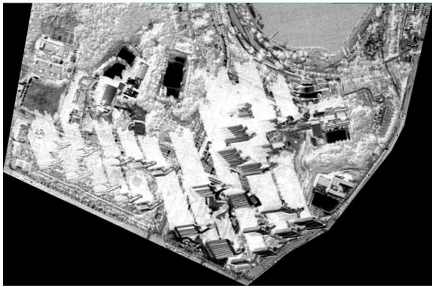
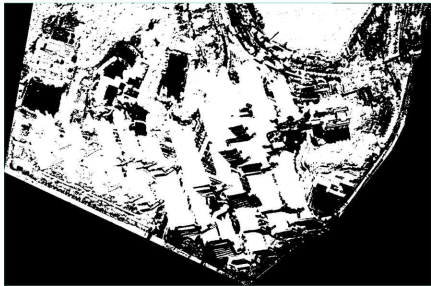
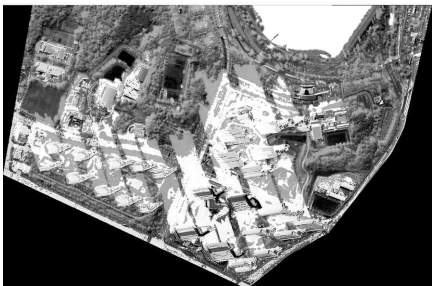
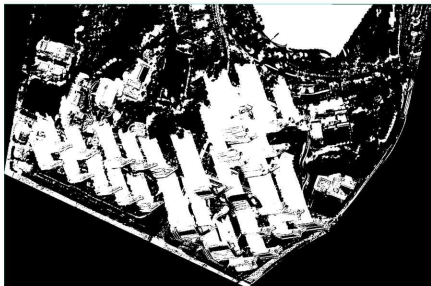
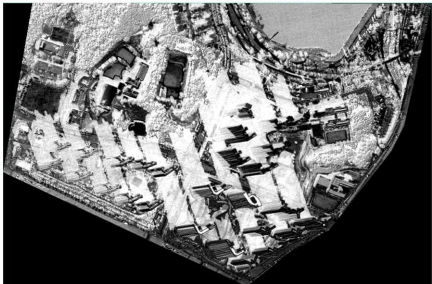

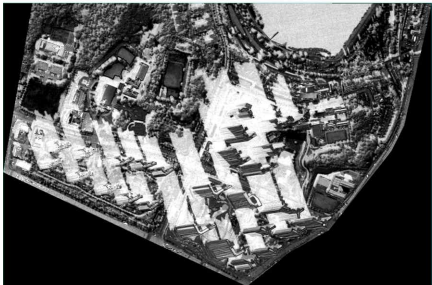
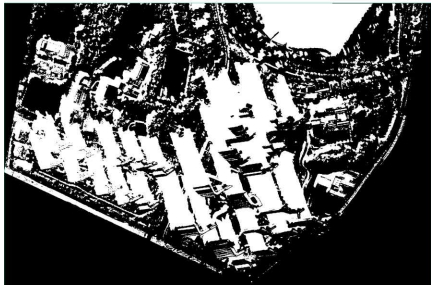
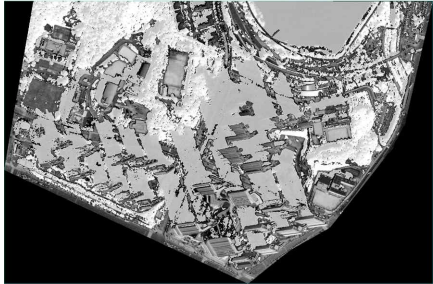
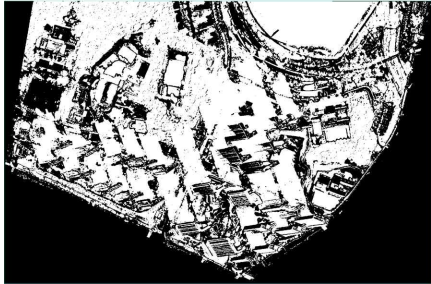
추출을 통해 정량적 결과 분석을 수행할 예정이다. 그림 5-6은 2021년 10월 24일에 국토위성으로 촬영한 영상으로 경기도 수원시에 위치한 국토지리정보원 주변 지역을 일부 사용하였다. 해당 영역은 위의 실험 자료로 사용한 영역과 유사하게 건물, 건물그림자, 수계를 포함하고 있다.



<그림 5-6> 2021년 10월 24일 촬영된 국토위성 영상 일부(경기 수원시)

<표 5-3>은 알고리즘의 적용 결과와 이진화 결과를 보여준다. SI와 NSVDI 알고리즘은 육안상 기존의 K3A의 적용 결과보다 수계와의 구분이 용이하였으나 이진화 알고리즘으로 주변 건물, 도로에서 그림자만을 분리하기는 어려웠다. OSI는 기존 결과와 달리 수계와 유사한 밝기 값을 가지고 있으며, 특히 녹지에 생긴 그림자가 다른 밝기 값을 가져 낮은 성능을 보인 것으로 판단한 것과 달리 이진화 결과 그림자 영역의 구분이 용이한 것을 확인하였다. NSI와 LSI는 기존의 적용결과와 유사한 특성을 보였으며, NSI에서 가장 그림자 구분이 용이하여 다른 알고리즘에 비해 안정적으로 그림자 탐지 성능을 보일 것으로 기대된다.

<표 5-3> 국토위성 적용 결과

알고리즘	알고리즘 적용 결과	이진화 결과
SI		
OSI		
NSVDI		
NSI		
LSI		

4. 결론

본 연구에서는 5개(SI, OSI, NSVDI, NSI, LSI)의 그림자 탐지 알고리즘을 다목적실용위성 3A호와 국토위성에 적용하여 각각의 알고리즘 성능을 비교하였으며, 고해상도 위성영상에서 그림자의 픽셀단위 정보 제공 가능성을 확인하였다. 특히 NSI는 비교적 단순한 계산식에도 불구하고 좋은 성능을 보였다.

국토위성의 절대복사보정계수가 확보된 이후 다시기의 영상을 이용하여 알고리즘의 성능평가를 추가적으로 진행할 예정할 예정이며, 다음 두 가지의 방법을 보완한다면 그림자 탐지 성능이 더 향상될 수 있을 것으로 기대된다.

- 그림자와 특성이 유사한 수계, 도로 등의 객체 분리 혹은 전처리를 통한 성능 향상
- 그림자 영역의 값의 특성을 이용한 이진화 알고리즘의 개선

최종적으로 고해상도 위성영상으로부터 추출된 건물 등 지형지물의 그림자 정보는 구름 등 국토위성의 픽셀단위 품질 정보와 같이 제공되어 사용자들이 보다 쉽게 위성영상을 다양한 분야(객체탐지, 변화탐지 등)에 활용하는데 기여할 수 있을 것으로 사료된다. 뿐만 아니라 그림자로 인해 가려진 위치의 영상 복원을 통해 영상 사용률 향상을 시킬 수 있고, 그림자 길이로 부터 건물의 높이를 추정하는 등 3차원 정보와의 융·복합 활용도 가능할 것으로 기대된다.

참고문헌

- 정세정, 박주언, 이원희, & 한유경. (2020). 태양과 플랫폼의 방위각 및 고도각을 이용한 이중 센서 영상에서의 객체기반 건물 변화탐지. *대한원격탐사학회지*, 36(5), 989-1006.
- Benarchid, O., Raissouni, N., El Adib, S., Abbous, A., Azyat, A., Achhab, N. B., ... & Chahboun, A. (2013). Building extraction using object-based classification and shadow information in very high resolution multispectral images, a case study: Tetuan, Morocco. *Canadian Journal on Image Processing and Computer Vision*, 4(1), 1-8.
- Fang, H., Wei, Y., Luo, H., and Hu, Q. (2019). Detection of Building Shadow in Remote Sensing Imagery of Urban Areas With Fine Spatial Resolution Based on Saturation and Near-Infrared Information. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(8), 2695-2706.
- Fu, H., Zhou, T., & Sun, C. (2020). Object-based shadow index via illumination intensity from high resolution satellite images over urban areas. *Sensors*, 20(4), 1077.
- Han, H., Han, C., Lan, T., Huang, L., Hu, C., and Xue, X. (2020). Automatic shadow detection for multispectral satellite remote sensing images in invariant color spaces. *Applied Sciences*, 10(18), 6467.
- Jiang, J., Tian, Y., Wang, M., Zheng, Y., and Yu, T. (2013) A shadow detection algorithm for remote sensing images. *Journal of Computational Information Systems*, 9, 3783-3790.
- Ma, H., Qin, Q., & Shen, X. (2008, July). Shadow segmentation and compensation in high resolution satellite images. In *IGARSS 2008-2008 IEEE International Geoscience and Remote Sensing Symposium* (Vol. 2, pp. II-1036). IEEE.
- Mostafa, Y. (2017) Review on Various Shadow Detection and Compensation Techniques in Remote Sensing Images, *Canadian Journal of Remote Sensing*, Vol 43(6), 545-562.
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66.
- Sirmacek, B., & Unsalan, C. (2008, October). Building detection from aerial images using invariant color features and shadow information. In *2008 23rd International Symposium on Computer and Information Sciences* (pp. 1-5). IEEE.
- Zhang, H., Sun, K., and Li, W. (2014). Object-oriented shadow detection and removal from urban high-resolution remote sensing images. *IEEE transactions on geoscience and remote sensing*, 52(11), 6972-6982.

제6장

고해상도 위성영상 기반 식생지수 산출 시범 적용 실험

1. 연구의 배경 및 목적
2. 실험 내용
3. 실험 결과
4. 결론 및 기대효과

1. 연구의 배경 및 목적

우리나라 전 국토의 70%는 식생(산림)으로 이루어져 있으며 도시 내 녹지영역은 환경적 측면, 정서적 측면에서 그 중요성이 대두됨에 따라 도시지역 또한 옥상녹화, 도심공원 조성 등의 도시 녹화사업을 통해 식생 영역을 확장시키고 있다. 그 동안의 식생 관측에서는 주로 관측폭이 넓은 영상인 Landsat, MODIS 등 중·저해상도 영상을 이용한 연구가 주를 이루었으나 고해상도 위성영상 취득이 가능해지고, 식생 영역이 도시지역으로 확장됨에 따라 고해상도 위성영상 기반의 도시 내 식생 영역 탐지를 위한 연구가 필요하다. 특히, 고해상도 광학위성인 국토위성이 발사됨에 따라 도시지역의 식생 탐지 등에 대한 활용성이 더욱 높아질 것으로 평가되고 있다 (강민조와 임용호, 2018).

일반적으로 광학위성영상 기반의 식생 영역 추출 방법은 다중 분광 밴드를 이용하여 각 파장대역 영상 간의 차, 비, 선형조합 등 여러 가지 방법으로 구현되어 식생 분포, 활력도를 나타낼 수 있는 식생지수를 이용한다 (김응남, 2012). 현재까지 제안되고 있는 식생지수는 약 100여종 이상 있으며 계절에 따라 생장 및 활력 특성이 나타내는 식생지수는 식생 활력도, 생물량, 엽면적 지수와 같은 생물리학적 정보를 산출 시 가장 큰 오차 요인 중 하나인 대기 효과에 대한 보정이 필요하다 (Jensen, 2015). 본 연구는 고해상도 국토위성에 적용 가능한 식생지수 선정하고 선정된 식생지수를 Sentinel-2 위성영상에 적용하여 ① 연구지역(산림, 농지, 인조잔디)에 따른 식생지수의 차별성과 특성을 비교 분석하고 ② 고해상도 위성영상인 KOMPSAT-3A로 도시의 식생을 확인할 수 있음에 따라 도시 내 식생영역인 옥상 녹화 유지여부 모니터링 가능성 분석을 목표로 한다.

2. 실험 내용

가. 국토위성영상에 적용 가능한 식생지수

식생지수는 영상 내 식물의 상대적인 분포량과 활동성, 엽록소함량 등을 양적으로 나타낼 수 있는 척도이며 관측된 각 파장대 영상 간의 비율, 차분 등 여러 가지 방법을 통해 산출할 수 있다 (나상일 등 2016). 식생지수는 크게 3가지(일반 식생지수, 대기 조정 식생지수, 토양 조정 식생지수)로 분류할 수 있다. 현재까지 제안된 식생지수는 약 100여종 이상이 있으나 본 연구에서는 먼저 국토 위성에 적용 가능한 식생지수를 조사하였다. Xue and Su (2017)가 요약한 118개의 식생지수들 중

국토위성의 다분광 센서로 취득된 영상에 적용 가능한 식생지수는 48개였으며, 그 중에서 중복된 식을 제외하면 총 39개 식생지수가 도출된다. 본 연구에서 시범 적용할 식생지수는 39개 식생지수에서 일반 식생지수, 대기 조정 식생지수, 토양 조정 식생지수별 각 3개씩 선정하여 총 9개의 식생지수를 선정하였다(표 6-1). 표 6-1에 선정된 식생지수에서 ρ_{blue} 은 청색 파장대의 반사율, ρ_{green} 은 녹색 파장대의 반사율, ρ_{red} 적색 파장대의 반사율, ρ_{nir} 근적외선 파장대의 반사율을 나타낸다.

<표 6-1> 선정된 식생지수

Vegetation Indices		Equation	Reference
General Vegetation Index	GLI (Green Leaf Index)	$GLI = \frac{2^* \rho_{green} - \rho_{red} - \rho_{blue}}{2^* \rho_{green} + \rho_{red} + \rho_{blue}}$	Louhaichi et al., 2001
	NDVI (Normalized Difference Vegetation Index)	$NDVI = \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red}}$	Rouse et al., 1974
	TDVI (Transformed Difference Vegetation Index)	$TDVI = 1.5 \frac{\rho_{nir} - \rho_{red}}{\sqrt{\rho_{nir}^2 + \rho_{red} + 0.5}}$	Bannari et al., 2002
Atmospherically Resistant Vegetation Index	ARVI (Atmospherically Resistant Vegetation Index)	$ARVI = \frac{\rho_{nir} - RB}{\rho_{nir} + RB}$ where, $RB = \rho_{red} - \gamma(\rho_{blue} - \rho_{red})$ γ : 대기교정계수(1.0)	Kaufman and Tanré, 1992
	VARI (Visual Atmospheric Resistance Index)	$VARI = \frac{\rho_{green} - \rho_{red}}{\rho_{green} + \rho_{red} - \rho_{blue}}$	Gitelson et al., 2002
	GARI (Green Atmospherically Resistance vegetation Index)	$GARI = \frac{\rho_{nir} - [\rho_{green} - \gamma(\rho_{blue} - \rho_{red})]}{\rho_{nir} + [\rho_{green} - \gamma(\rho_{blue} - \rho_{red})]}$ where, γ : 대기교정계수(1.7)	Gitelson et al., 1996
Soil Adjusted Vegetation Index	SAVI (Soil Adjusted Vegetation Index)	$SAVI = \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red} + L} (1 + L)$ where, L : 토양보정계수(0.5)	Huete, 1988
	MNLI (Modified Non-Linear Index)	$MNLI = \frac{[(\rho_{nir}^2 - \rho_{red})(1 + L)]}{\rho_{nir}^2 + \rho_{red} + L}$ where, L : 토양보정계수(0.5)	Yang et al., 2008
	EVI (Enhanced Vegetation Index)	$EVI = 2.5 \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + C_1 \rho_{red} - C_2 \rho_{blue} + L}$ where, L : 대기보정계수(1.0) C_1 : 수관보정계수(6.0) C_2 : 수관보정계수(7.5)	Huete et al., 2002

나. 중해상도 위성영상 기반 지역별 시계열 식생지수 특성 분석

1) 연구지역 및 자료

본 연구에서 식생지수별 시계열 특성 비교 분석의 연구지역은 산림지역과 농업지역, 도심 등 다양한 토지피복을 가지고 있는 광주광역시 서구 인근으로 사월산(산림), 서석평야(논), 상무시민공원 내 종합운동장(인조잔디)으로 선정하였다(그림 6-1). 식생지수별 시계열 특성 비교·분석을 위하여 사용한 데이터는 Sentinel-2 위성영상과 토지피복도 세분류 자료이다.



<그림 6-1> 시계열 식생지수 특성 분석을 위한 연구지역

Sentinel-2 위성영상은 2020년 3월부터 11월까지 획득된 영상 중 운량 10% 미만인 영상을 사용하였으며 연구지역에 해당되는 타일은 T52SBD타일이다. Sentinel-2 위성영상은 QGIS (Quantum GIS) 소프트웨어 내 제공되는 SCP 플러그인 (Semi-Automatic Classification Plugin) 모듈을 이용하여 영상을 다운받고 전처리(DN to Reflectance)와 DOS (Dark Object Subtraction) 대기보정을 수행하였다.

본 연구에서는 연구지역(사월산, 서석평야, 상무시민공원 내 종합운동장)의 ROI (Region Of Interest)를 추출하기 위해 세분류 토지피복도를 이용하였다. 토지피복도는 위성영상과 항공사진을 이용하여 지표면의 상태를 표현한 지도로 해상도에 따라 대분류(30m), 중분류(5m), 세분류(1m)로 구분되어 TIFF파일(대분류) 또는 SHP파일(중분류, 세분류) 형태로 환경부에서 제공하고 있다. 세분류 토지피복도의 경우, 41개의 항목으로 구성되어 있으며 산림지역인 사월산의 영역을 추출

하기 위해서 ‘활엽수림’, ‘침엽수림’, ‘혼효림’으로 구성된 항목으로 추출하였고(그림 6-1에서 초록색), 농업지역인 서석평야를 추출하기 위해서는 ‘경지정리가 된 논’ 항목에 대해서 추출하였으며(그림 6-1에서 노란색), 상무시민공원 내 종합운동장(인조잔디)을 추출하기 위해서는 ‘문화·체육·휴양 시설’ 항목에 대해 추출하였다(그림 6-1에서 빨간색). 해당 연구지역에 대해 이용된 Sentinel-2 위성영상과 토지피복도의 자료 획득 시기와 출처는 표 6-2와 같다.

<표 6-2> 시계열 식생지수 특성 분석을 위해 사용한 자료

구분	종류	취득날짜	출처
위성영상	Sentinel-2 (T52SBD)	2020.03.08.	유럽우주국 (ESA, European Space Agency)
		2020.03.18.	
		2020.03.23.	
		2020.04.07.	
		2020.04.27.	
		2020.05.12.	
		2020.06.21.	
		2020.08.20.	
		2020.09.04.	
		2020.10.24.	
		2020.11.13.	
토지피복도	세분류	2020년 토지피복도* * 2019년 영상을 이용해 2020년에 현행화한 자료	환경부

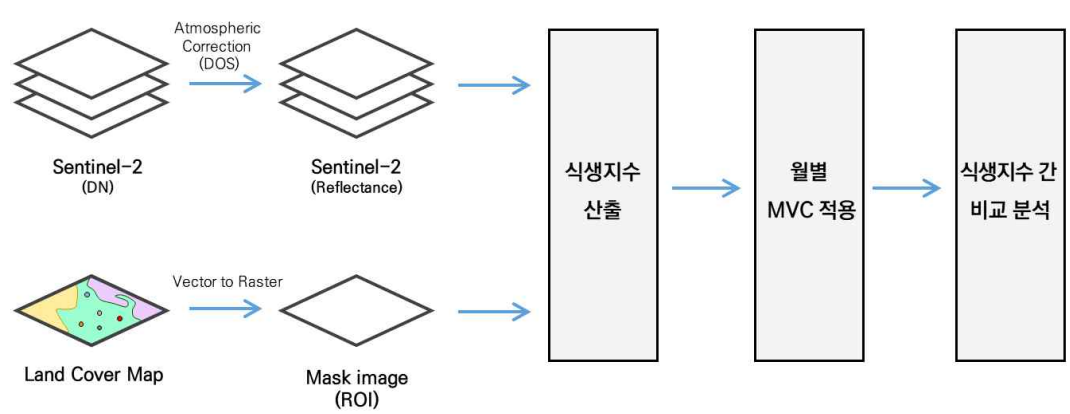
2) 방법

Sentinel-2 위성영상을 이용한 연구 흐름도는 그림 6-2과 같다.

대기보정까지 전처리된 Sentinel-2 영상을 이용하여 ENVI/IDL 상용 소프트웨어를 통해 연구 지역에 대해 9개 식생지수를 산출한 후 시계열 분석을 수행하였다. 식생지수의 시계열 분석을 위해서는 연구지역에 대한 식생지수만 추출하는 것이 중요하며 (나상일 등., 2020), 이때 마스크(mask) 영상을 이용하여 ROI를 설정하였다.

마스크 영상은 세분류 토지피복도를 이용하여 제작하였다. 세분류 토지피복도는 vector 형태로 환경부에서 shp포맷으로 제공되며, 연구지역에 해당되는 항목만 추출한 다음 raster 형태로 변환하여 마스크 영상을 제작했다. 연구지역 내 산출된 식생지수는 각 화소를 평균 내어 해당 월의 대표

값으로 나타냈으며, 해당 월에 취득된 영상이 다수일 경우에는 취득된 영상 중 화소별 최댓값을 선정하는 MVC (Maximum Value Composite) 기법을 적용하였다. MVC는 MODIS 식생지수 산출물에 적용되고 있으며 구름의 영향을 제거하는 효과를 가지고 있다. 연구지역별 산출된 9개의 시계열 식생지수는 지역별 식생지수의 차이와 특성 및 지수 간의 상관성 분석 등을 통해 지수 간 특성을 비교 분석하였다.




<그림 6-2> 연구 흐름도

다. 고해상도 위성영상 기반 옥상녹화 추출 가능성 분석

1) 연구지역 및 자료

본 연구에서 고해상도 위성영상을 이용하여 옥상 녹화 추정 가능성 분석을 수행한 지역은 경기도 수원시 국토지리정보원 인근 옥상 내 식생을 포함하고 있는 건물이다(그림 6-3). 건물 옥상에 존재하는 식생을 추출하기 위하여 사용한 데이터는 KOMPSAT-3A 위성영상과 건물통합정보 자료이다. KOMPSAT-3A 위성영상은 건물통합정보와 중첩하여 사용하기 위해 수원시 지역을 촬영한 영상 중 촬영각이 2.95도인 영상을 사용하였다. KOMPSAT-3A 위성영상은 한국항공우주연구원으로부터 기본영상(L1R)을 제공받아 국토위성센터의 ‘정밀정사영상생성시스템’을 이용하여 정밀 기하보정과 정밀정사영상을 처리한 위성정사영상(L2G)로 제작하여 사용하였다.



<그림 6-3> 옥상녹화 추출 가능성 분석을 위한 연구지역

그림 6-3은 옥상녹화 추출 가능성 분석의 연구지역에 대한 KOMPSAT-3A 위성영상과 건물 통합정보로, 실험을 진행할 해당 건물은 건물통합정보에서 추출하여 그림 6-3에서 빨간색 선으로 나타냈다. 그림 6-3(b)는 옥상 내 식생을 포함하고 있는 해당 건물로 R/G/B 밴드 조합한 영상이며, 그림 6-3(c)는 NIR/R/G 밴드 조합한 영상이다. 그림 6-3(c)와 같이 근적외선 대역 밴드를 이용하여 밴드조합할 경우, 자연색상조합인 그림 6-3(b)와 달리 식생이 붉은색으로 강조되어 식생을 육안판독하는데 용이하다.

본 연구에서는 건물 내 식생만을 추출하고 건물 주변의 가로수, 도심공원 등과 같이 주변 식생 추출 방지를 위해 건물통합정보를 이용하였다. 건물통합정보는 연속수치형도의 건물레이어와 건축행정시스템(세움처)의 건축물대장 속성정보를 건물단위로 통합하여 구축한 건물 정보로 SHP 파일 형태로 국토교통부에서 제공하고 있다. 해당 연구지역에 대해 이용된 KOMPSAT-3A 위성영상과 건물통합정보의 자료 획득 시기와 출처는 표 6-3과 같다.

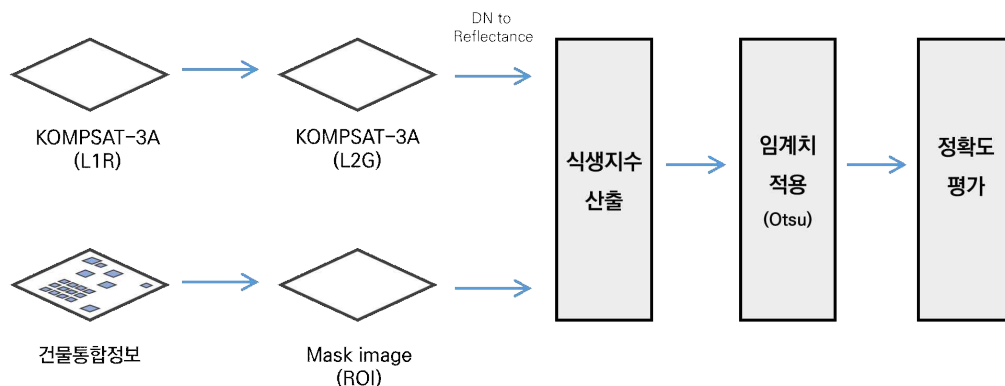
<표 6-3> 옥상녹화 추출 가능성 분석을 위해 사용한 자료

구분	종류	취득날짜	출처
위성영상	KOMPSAT-3A	2019.01.29.	한국항공우주연구원
건물통합정보	경기도	2021년 11월 자료	국토교통부

2) 방법

KOMPSAT-3A 위성영상을 이용하여 옥상녹화 추출 가능성 분석을 위한 연구 흐름도는 그림 6-4와 같다. 기본영상(L1R)에서 위성정사영상(L2G)로 처리된 KOMPSAT-3A 영상은 ENVI/IDL 상용 소프트웨어를 통해 DN값을 Reflectance로 변환한 후, 9개의 식생지수를 산출하였다.

9개의 식생지수로 산출된 영상에서 해당 건물 영역의 식생지수만 추출하기 위해 마스크 영상을 이용하여 해당 건물 영역을 ROI 설정하였으며 마스크 영상은 건물통합정보를 이용하여 제작하였다.




<그림 6-4> 옥상녹화 추출 가능성 분석을 위한 연구흐름도

건물통합정보는 vector 형태로 국토교통부에서 shp포맷으로 제공되며, 해당 vector를 raster 형태로 변환하여 마스크 영상을 제작했다. 해당 건물 영역 내 산출된 식생지수는 Otsu 알고리즘을 적용하여 이진화한 후 9개 식생지수에 대한 정확도 평가를 수행하였다. 각 식생지수별 옥상 내 식생 추출에 대한 정확도평가를 위해 식생 영역을 수동으로 추출하여 참값으로 사용하였다.

정확도 평가는 본 연구보고서의 제4장과 동일하게 정확도(Accuracy), 재현율(Recall), 정밀도(Precision), F1-Score로 평가하였다. 위 평가지표들을 설명하기에 앞서 오차행렬(confusion matrix)을 표현하면 그림 6-5와 같다. 오차행렬은 이진 분류에서 성능평가 시 활용성이 높은 지표로 분류모델의 예측오류와 더불어 어떤 항목에서 오류가 발생하는 지를 보여주는 지표이다.

오차행렬에서 TP(True Positive), TN(True Negative)는 실제 값과 분류 값이 모두 참인 경우와 모두 거짓인 경우이며, FP(False Position)은 실제 값은 거짓이지만 분류는 참인 경우이며, FN(False Negative)는 실제 값은 참이지만 분류는 거짓인 경우를 의미한다.

이때 정확도는 분류결과가 실제값과 얼마나 같은지 판단하는 지표로 식 6-1과 같다.



<그림 6-6> 연구지역별 NDVI 시계열 변화

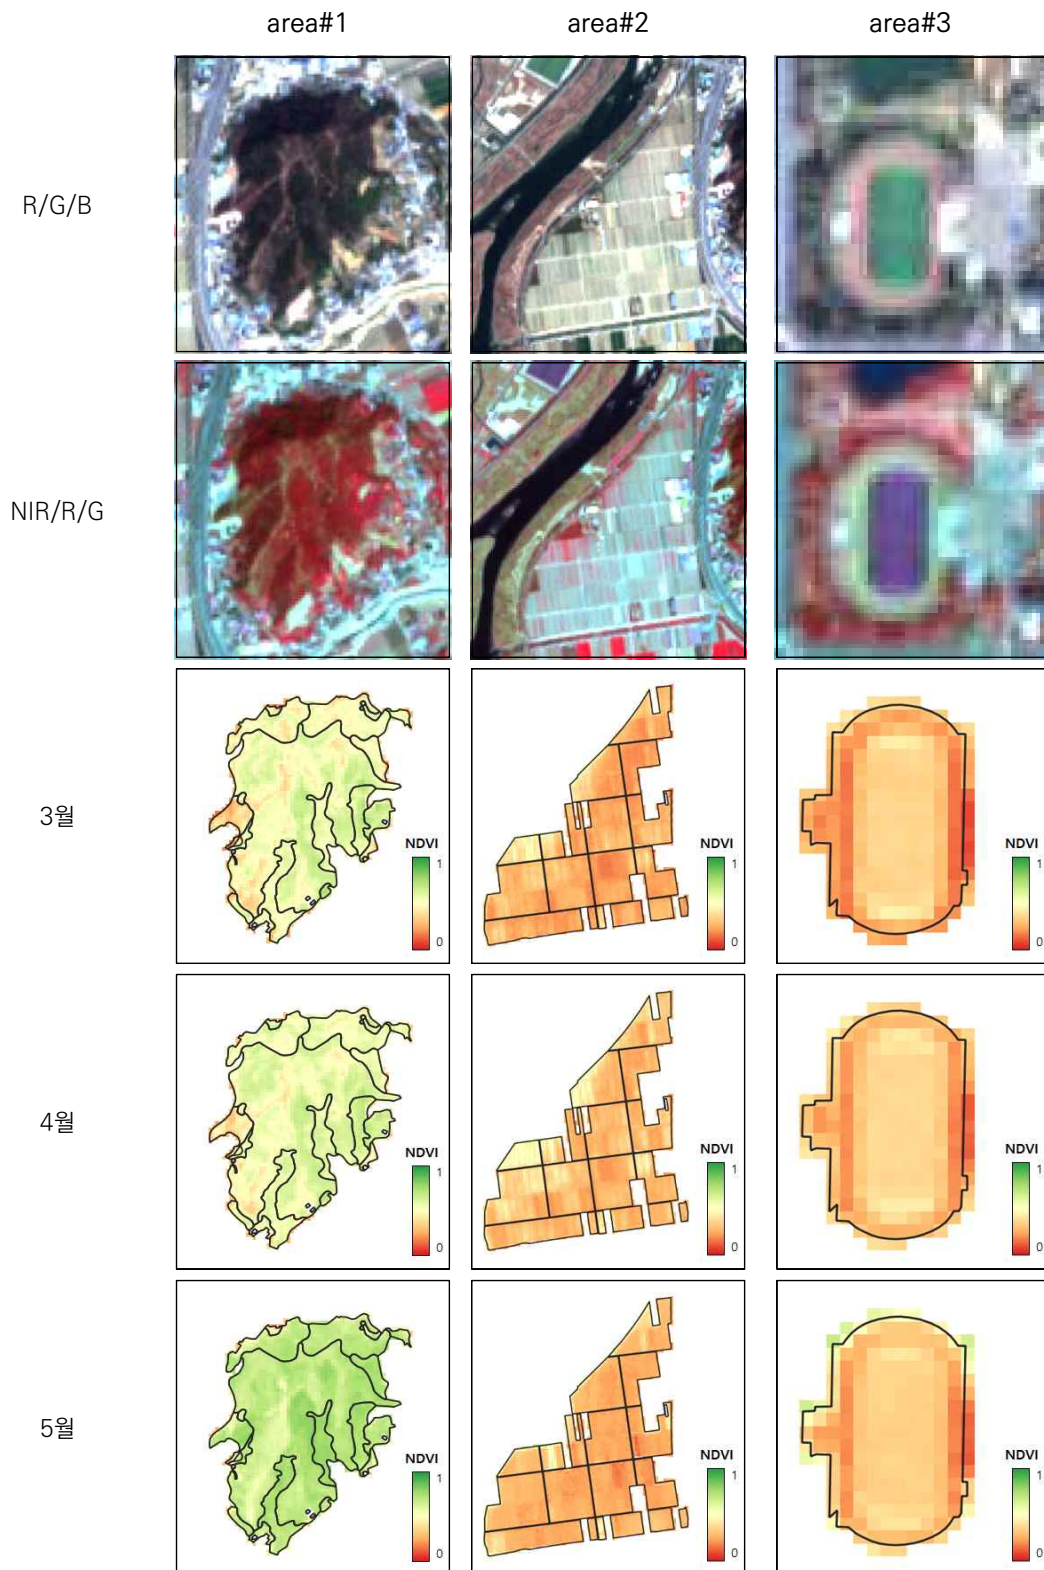
농업지역인 서석평야(area#2)는 8월 전까지는 0.3 이하의 값을 가지다가 8월에 급격히 증가하여 9월에 0.781로 최대값을 나타낸 후, 10월에는 0.276 으로 급격히 감소하였다. 이는 벼의 작업 일정을 나타낸 표 6-4와 같이 9월 말부터 10월 초 벼의 수확시기로 인해 NDVI 값이 급감한 것을 알 수 있었으며, 6월까지의 논에 물을 가두기 및 모내기 등으로 인해 논에 존재하는 물의 영향으로 NDVI값이 낮은 것을 알 수 있다. 8월과 9월은 벼가 익음에 따라 NDVI가 높은 것을 알 수 있다.

도심공원인 상무시민공원 내 종합운동장은 인조잔디(area#3)로 이루어져 식생이 없어 대체로 0.3 으로 큰 변화없이 일정한 것을 알 수 있었다. 인조잔디는 고무와 플라스틱으로 구성되어 연중 비슷한 NDVI 값을 가진다.

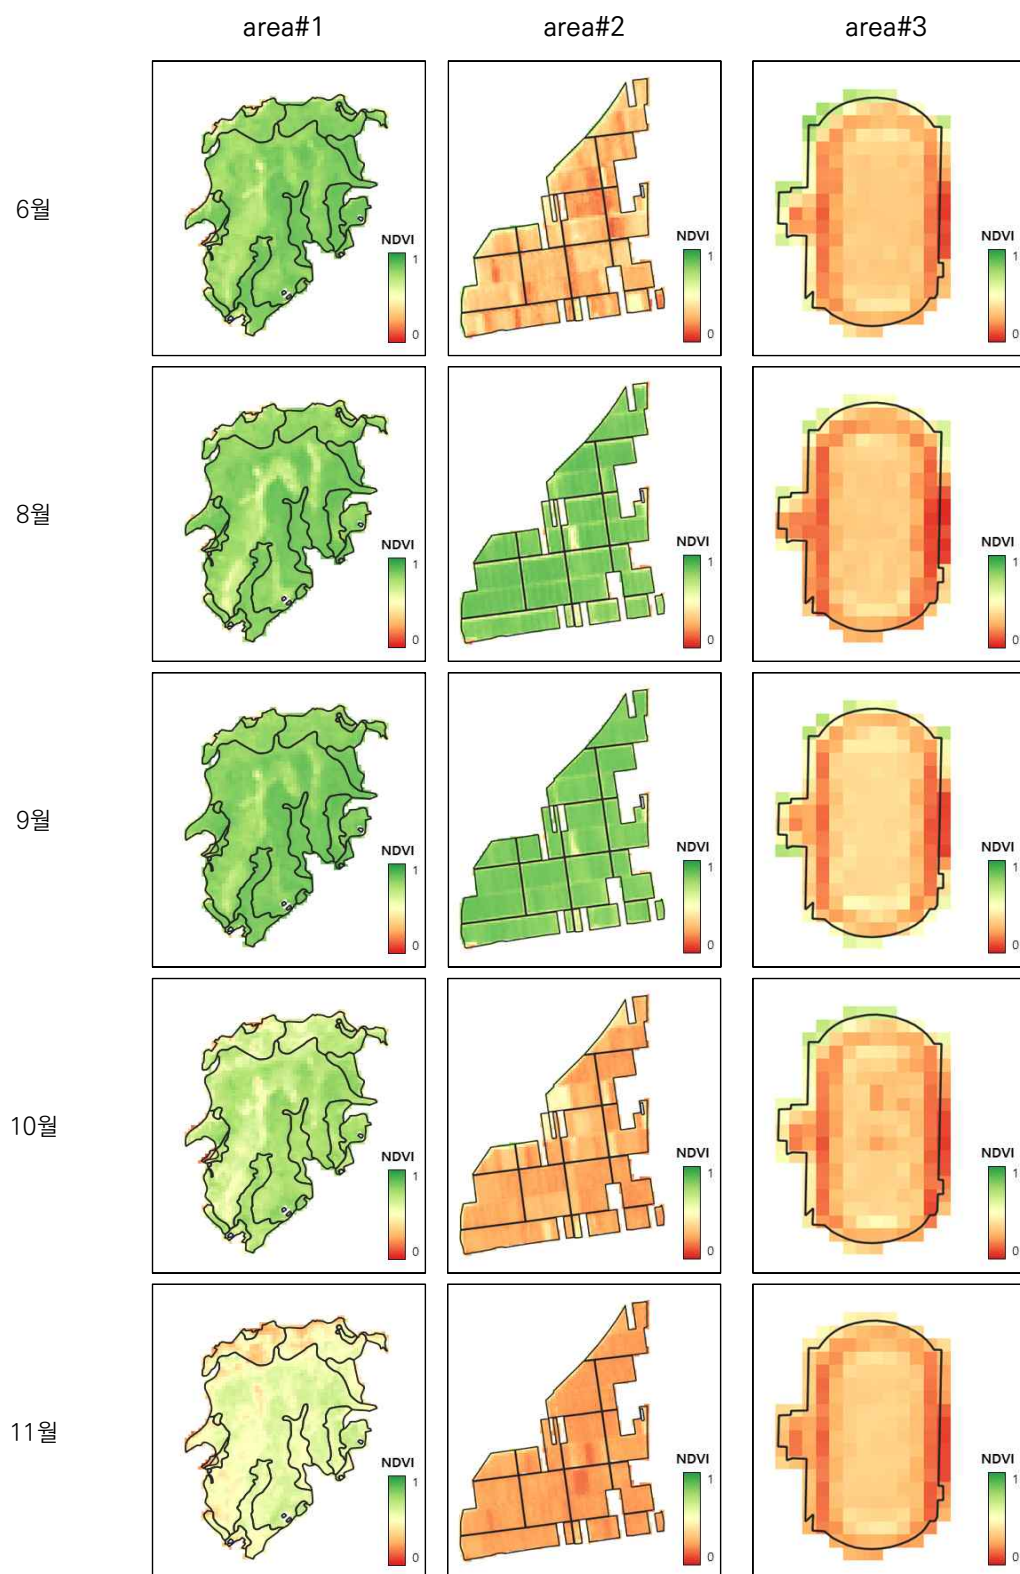
<표 6-4> 벼의 농작업일정

	1월	2월	3월	4월	5월	6월	7월	8월	9월	10월	11월	12월
객토, 퇴비주기	■	■										
논에 물 가두기			■	■	■							
물 깊이대기					■	■						
모내기 및 중간물때기						■	■	■				
이삭								■	■			
벼 익음때									■	■		
수확기										■	■	
벼짚깎기, 논갈이											■	■

※ 출처 : 농촌진흥청 농사백과



<그림 6-7> 연구지역별 NDVI 공간적 분포(3월~11월) (계속)



<그림 6-7> 연구지역별 NDVI 공간적 분포(3월~11월)


2) 연구지역별 식생지수 간 특성 분석

산림지역인 사월산(area#1), 농업지역인 서석 평야(area#2), 도심공원인 상무시민공원 내 인조 잔디로 이루어져있는 종합운동장(area#3)에 대해서 9개 식생지수들의 시계열특성을 비교·분석하였다. 그림 6-8는 각 연구지역을 대상으로 앞서 선정되었던 9개의 식생지수들의 시계열 변화 그래프를 나타낸다. 시계열을 분석을 통해 다른 식생지수들은 NDVI와 동일한 추세를 보이는데, NDVI와 가장 유사한 지수 및 가장 상이한 지수는 어떤 건지를 파악하고 지수들의 특성을 비교 분석하였다.


그림 6-8(a)는 사월산에 대한 식생지수 변화 그래프이다. GLI와 VARI를 제외한 모든 식생지수는 6월까지 증가하다가 8월, 9월에 최대값을 나타냈다. 5월의 식생지수는 4월의 식생지수와 큰 차이 없이 소폭 상승했지만 GLI와 VARI의 경우, 5월에 대폭 감소했다. 이는 근적외선 파장대 밴드를 이용하는 다른 식생지수와는 달리 가시광선 파장대 밴드로만 제작된 식생지수이기 때문에 식생의 작은 변화를 감지하지 못 한 것으로 사료된다. 따라서 산림지역에서는 근적외선 파장대 밴드를 포함한 식생지수가 가시광선 파장대 밴드로만 제작된 식생지수보다 식생에 대해 민감하게 반응한 것을 알 수 있다.

표 6-5는 산림지역에서 식생지수 간 상관성 분석 결과이다. 그 결과, NDVI와 상관성이 가장 높은 지수는 0.994로 ARVI이다. ARVI(Atmospherically Resistant Vegetation Index)는 청색 밴드(blue band)를 이용하여 적색밴드(red band)에 영향을 주는 대기의 영향을 감소한 식생지수로, NDVI기반 산출식에서 대기의 영향을 줄이기 위해 개발하였기 때문에 NDVI와 유사한 결과를 나타내는 것이라 판단된다. 반면 NDVI와 상관성이 가장 낮은 지수는 0.734로 GLI이다. GLI(Green Leaf Index)는 가시광선 파장대 밴드(Red-Green-Blue)로만 계산되었기 때문에 근적외선 파장대 밴드를 사용한 다른 식생지수들에 비해 NDVI와의 상관성이 비교적 낮은 것으로 판단된다.


산림지역에 대한 전반적인 분석 결과, 일반 식생지수와 대기저항 식생지수에서는 근적외선 파장대 밴드가 포함된 지수들 간은 상관성이 높았지만, 가시광선 대역으로만 이루어진 지수와는 상관성이 비교적 낮았다. 그러나 가시광선 파장대 밴드로만 구성된 지수(GLI, VARI) 간의 상관성은 높은 것으로 나타났다. 토양보정식생지수 분류에서는 근적외선 파장대 밴드가 다 포함되어 있어 각 지수들 간의 높은 상관성을 나타냈다.



(a) 산림지역



(b) 논 지역



(c) 인조잔디 지역

<그림 6-8> 연구지역별 식생지수 시계열 변화; (a)산림, (b) 논, (c)인조잔디

<표 6-5> 산림지역에 대한 식생지수 상관관계

	General Vegetation Indices			Atmospherically Resistant Vegetation Indices			Soil Adjusted Vegetation Indices		
	NDVI	GLI	TDVI	ARVI	VARI	GARI	SAVI	MNLI	EVI
NDVI	1								
GLI	0.734	1							
TDVI	0.933	0.588	1						
ARVI	0.994	0.738	0.921	1					
VARI	0.800	0.942	0.663	0.833	1				
GARI	0.980	0.633	0.929	0.988	0.758	1			
SAVI	0.952	0.610	0.998	0.940	0.684	0.945	1		
MNLI	0.939	0.655	0.991	0.935	0.727	0.933	0.990	1	
EVI	0.932	0.580	0.993	0.929	0.685	0.946	0.991	0.989	1

그림 6-8(b)는 논에 대한 식생지수 변화 그래프이다. 모든 식생지수는 6월까지 큰 변화 없이 일정한 값을 유지하다가 8월에 급격하게 증가하였다. 급격하게 증가한 식생지수 중에 GARI가 가장 큰 폭으로 증가(+0.568)하였으며, GLI가 가장 소폭 증가(+0.084)하였다. 또한 9월말부터 10월초 수확기가 지나면서 10월에 모든 식생지수는 급격히 감소하게 된다. 이때 GARI와 GLI는 가장 큰 폭으로 증가하고, 가장 소폭으로 증가한 식생지수이면서 가장 큰 폭으로 감소(-0.580)하고, 가장 소폭(-0.256)으로 감소한 식생지수이다. GARI는 NDVI보다 엽록소 농도에 예민하면서 대기 영향에 덜 민감한 식생지수로서 식생의 변화에 크게 영향을 받는 것으로 판단되며, GLI는 산림 지역에서 분석한 결과와 같이 근적외선 파장대 밴드가 없어 식생에 덜 민감하기 때문에 지수의 변화가 크지 않은 것으로 판단된다. 따라서 산림지역과 동일하게 논 지역에서도 근적외선 파장대 밴드를 포함한 식생지수가 가시광선 파장대 밴드로만 제작된 식생지수보다 식생에 대해 민감하게 반응한 것을 알 수 있다. 표 6-6은 논 지역에서 식생지수 간 상관성 분석 결과이다. 그 결과, NDVI와 상관성이 가장 높은 지수는 0.998로 ARVI이며, NDVI와 상관성이 가장 낮은 지수는 0.920으로 GLI이다. 이는 산림지역에서의 상관성 분석 결과와 동일하다고 판단된다.

논 지역에 대한 전반적인 분석결과, 일반 식생지수와 대기저항 식생지수에서는 근적외선 파장대 밴드가 포함된 지수들 간의 상관성이 높았지만, 가시광선 대역으로만 이루어진 지수와는 상관성이 비교적 낮았다. 그러나 가시광선 파장대 밴드로만 구성된 지수(GLI, VARI) 간의 상관성은 높은 것으로 나타났다. 이는 산림지역의 전반적인 분석결과와 동일하나 근적외선 파장대 밴드 포함 유무에

따른 상관성 결과가 산림지역 보다 논 지역에서는 그 차이가 크지 않았다. 토양보정식생지수 분류에서는 근적외선 파장대 밴드가 다 포함되어 있어 각 지수들 간의 높은 상관성을 나타냈다.

<표 6-6> 논 지역에 대한 식생지수 상관관계

	General Vegetation Indices			Atmospherically Resistant Vegetation Indices			Soil Adjusted Vegetation Indices		
	NDVI	GLI	TDVI	ARVI	VARI	GARI	SAVI	MNLI	EVI
NDVI	1								
GLI	0.920	1							
TDVI	0.986	0.906	1						
ARVI	0.998	0.919	0.974	1					
VARI	0.963	0.976	0.931	0.969	1				
GARI	0.995	0.890	0.970	0.998	0.951	1			
SAVI	0.991	0.909	0.999	0.981	0.938	0.978	1		
MNLI	0.997	0.938	0.982	0.995	0.970	0.990	0.987	1	
EVI	0.994	0.910	0.998	0.986	0.944	0.983	1.000	0.990	1

그림 6-8(c)는 종합운동장(인조잔디)에 대한 식생지수 변화 그래프이다. 모든 식생지수는 3월부터 11월까지 각 지수별 변화폭 0.1 내외의 일정한 값을 나타냈다. 식생은 계절에 따른 특성을 보이는데 일반적으로 개엽기, 성숙기, 낙엽기 등이 있다. 이러한 식생의 계절변화는 식생 활력 정도가 변화됨에 따라 식생지수도 변화되는 것을 볼 수 있다. 식생이 존재했던 산림지역과 논 지역에서는 식생의 계절적인 변화를 볼 수 있었으나 고무와 플라스틱으로 이루어진 인조잔디에서는 식생이 아니기 때문에 식생의 계절변화를 볼 수 없었다. 앞서 분석한 인조잔디 지역의 NDVI의 결과와 같이 모든 식생지수가 계절적인 변화를 나타내지 않고 연중 일정한 값을 나타냈으며 이는 식생지역이 아닌 것을 재확인할 수 있었다. 이처럼 식생이 없는 지역에 대해서는 NDVI 뿐만 아니라 모든 식생지수가 계절적 영향을 받지 않는 일정한 값을 나타낸다는 것을 알 수 있었으며 식생의 영향이 없기 때문에 지수 간 상관성분석은 본 실험결과에서 제외하였다.

따라서 본 연구를 통해 고해상도 국토위성에 적용 가능한 식생지수들을 Sentinel-2 영상에 시범 적용하고 각 연구지역에 따른 지수별 특성 차이를 비교 분석함으로써 상황별 활용 목적에 맞는 최적의 식생지수 도출을 위한 기반이 될 수 있을 것으로 기대된다.

나. 고해상도 위성영상 기반 옥상녹화 추출 가능성 분석

본 연구에서는 옥상녹화 추출 가능성 분석을 위해 식생을 포함하고 있는 건물에 대해 9개 식생 지수들을 적용한 후, Otsu 임계치를 주어 이진화하였다. 그림 6-9는 해당 건물(빨간색 선)에 대해 앞서 선정되었던 9개의 식생지수들을 적용한 결과와 이진화 영상을 나타낸다. 이진화 영상에서는 각 식생지수별 옥상 내 식생이 잘 추출되었는지 정확도평가를 위해 식생 영역(녹색선)을 수동으로 추출하여 참값으로 사용하였으며 그림 6-9(a), (b)에서 첫 번째 그림과 같다. 정확도평가는 정확도(Accuracy), 재현율(Recall), 정밀도(Precision), 정밀도와 재현율의 조화 평균인 F1 Score로 나타냈다(표 6-7). 정확도평가의 지표 중 정확도는 분류 클래스가 불균형한 경우 다른 지표들보다 높은 값을 나타낼 수 있기 때문에, 다른 지표까지 동시에 고려하여 정확도평가를 해야 한다.

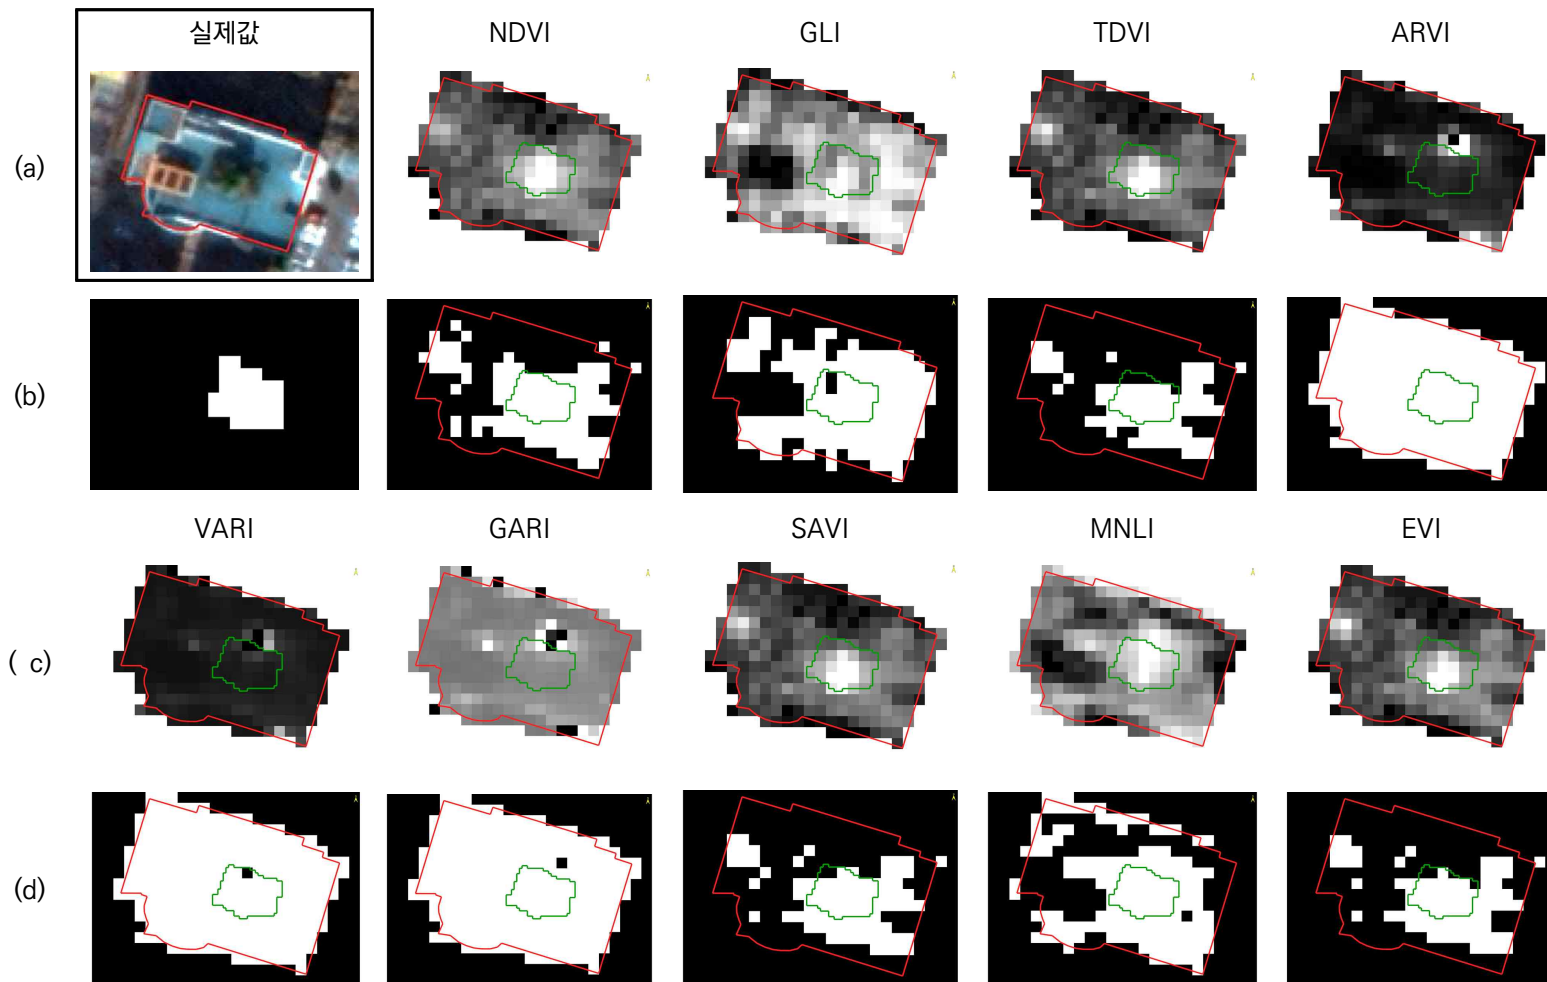
옥상녹화 추출 가능성 분석 결과에 대해 정확도평가 지표를 모두 고려했을 때, TDVI와 SAVI가 옥상 내 식생탐지에 가장 높은 정확도를 보였으며 VARI가 가장 낮은 정확도를 보였다. TDVI와 SAVI는 일부 토양이 노출된 지역의 식생을 관측할 때 토양의 밝기에 의한 오차를 최소화하기 때문에 토양이나 맨땅의 영향을 받는 도시환경에서 식생을 모니터링할 때 유용하다(Bannari 등, 2003).

VARI의 경우, 앞서 진행된 시계열 분석 결과와 동일한 이유로 다른 식생지수와 달리 가시광선 파장대 밴드로만 제작된 식생지수이기 때문에 식생의 작은 변화를 감지하지 못 한 것으로 사료된다. 옥상녹화 추출 가능성 분석 실험에서는 건물통합정보와 위성영상의 중첩 분석을 위해 직하로 촬영된 영상을 선정하는데 있어 사용 가능한 영상의 한계가 있었으며 이로 인해 식생활력도가 높은 여름철 영상이 아닌 겨울철 영상으로 실험함에 있어 옥상 내 식생을 추출하는데 한계가 있었다.

그러나 향후 한반도 지도제작 목적을 위해 직하 촬영을 우선시하는 국토위성영상을 이용하면 직하 위성영상의 수급이 수월해질 것으로 사료됨에 따라 여름철 촬영된 직하 영상을 이용하여 옥상 내 식생을 추출하면 더 높은 정확도를 나타낼 것으로 판단된다.

<표 6-7> 식생지수별 정확도평가 결과

	Accuracy	Recall	Precision	F1-Score
NDVI	0.829	0.968	0.283	0.438
GLI	0.742	1.000	0.211	0.348
TDVI	0.871	0.774	0.320	0.453
ARVI	0.524	1.000	0.127	0.225
VARI	0.520	0.968	0.122	0.217
GARI	0.524	1.000	0.127	0.225
SAVI	0.867	0.871	0.325	0.474
MNLI	0.742	1.000	0.211	0.348
EVI	0.864	0.806	0.313	0.450



<그림 6-9> (a), (c) 식생지수 적용 및 (b), (d) 이진화 결과

4. 결론 및 기대효과

본 연구에서는 국토위성에 적용 가능한 식생지수 9개를 선정하였고 선정된 9개의 식생지수를 Sentinel-2 위성영상에 적용하여 지역별(산림, 농지, 인조잔디) 각 식생지수들의 시계열 특성을 살펴보았으며 국토위성과 가장 유사한 스펙을 가진 KOMPSAT-3A 위성영상에 적용하여 도시 내 식생영역인 옥상녹화 추출 가능성 분석을 수행하였다.

Sentinel-2 위성영상을 이용하여 지역별 각 식생지수들의 시계열 특성 분석 결과, GLI, VARI는 근적외선 파장대 밴드를 주로 이용하는 다른 식생지수와 달리 가시광선 파장대 밴드로만 제작된 식생지수로 식생의 작은 변화를 감지하지 못 한 것으로 사료된다. 따라서 산림과 논 지역에서는 근적외선 파장대 밴드를 포함한 식생지수가 가시광선 파장대 밴드로만 제작된 식생지수보다 식생에 대해 민감하게 반응한 것을 알 수 있었다. 식생은 계절에 따른 특성을 보이는데 일반적으로 개엽기, 성숙기, 낙엽기 등이 있다. 이러한 식생의 계절변화는 식생 활력 정도가 변화됨에 따라 식생지수도 변화되는 것을 볼 수 있다. 식생이 존재했던 산림지역과 논 지역에서는 식생의 계절적인 변화를 볼 수 있었으나 고무와 플라스틱으로 이루어진 인조잔디에서는 식생이 아니기 때문에 모든 식생지수가 계절적인 변화를 나타내지 않고 연중 일정한 값을 나타내어 식생지역이 아닌 것을 재확인 할 수 있었다.

옥상녹화 추출 가능성 분석 결과, KOMPSAT-3A를 이용하여 산출된 옥상 내 식생탐지에는 9개의 식생지수들 중 토양이 노출된 지역의 식생을 관측할 때 토양의 밝기에 의한 오차를 최소화하는 TDVI와 SAVI가 높은 정확도를 나타냈으나 본 연구에서는 식생활력도가 높은 여름철 영상이 아닌 겨울철 영상으로 실험함에 있어 옥상 내 식생을 추출하는데 한계가 있었다. 향후 여름철 촬영된 직하 위성영상을 이용하여 옥상 내 식생을 추출하여 가능성 분석 실험이 필요하며 이와 더불어 시계열 영상을 확보하여 옥상 녹화 유지관리 모니터링을 위한 가능성 분석 실험도 필요하다.

본 연구결과를 통해 각 연구지역에 따른 지수별 특성 차이를 비교 분석함에 따라 활용 목적에 맞는 최적의 식생지수 도출을 위한 기반이 될 수 있을 것으로 기대되며 향후 도시 내 녹지 시설 관리를 위한 기초자료 및 지자체 옥상녹화 지원 사업의 업무에 활용할 수 있을 것으로 기대된다.

참고문헌

- 김응남 (2012), 원격탐사 입문, 에듀컨텐츠휴피아
- 강민조와 임용호 (2018), 국토정책 지원을 위한 위성정보 활용수요에 관한 연구, 건설보고서, 2018(9).
- 나상일, 박찬원, 정영근, 강천식, 최인배, 이경도 (2016), 원격탐사 기반 맥류 작황 추정을 위한 최적 식생지수 선정, 대한원격탐사학회, 제 32권, 5호, pp. 483~497.
- 나상일, 안호용, 이경도, 박찬원, 홍석영, 소규호. (2020), 논벼 작황 분석을 위한 MCD12Q1 기반 시계열 마스크 맵 작성, 한국농공학회 학술대회초록집, pp. 243-243.
- 박정기, 고신영, 조기성 (2013), KOMPSAT-2 영상 및 고해상도 항공영상을 이용한 도심지역 식생분류, 한국지형공간정보학회지, 제 21권, 4호, pp. 21~27.
- 조은래, 김경환, 유환희 (2009), 고해상도 위성영상을 이용한 토지이용변화 분석. 대한공간정보 학회지, 17(1), pp. 3-11.
- 최재완 (2020). 국토모니터링을 위한 위성영상 활용방법 및 발전 방향, 국토, pp. 5-15.
- 한국항공우주연구원 (2014), 아리랑위성영상을 활용한 옥상녹화 모니터링 기술 개발
- 한동엽, 송정현, 변영기 (2017), 상대 방사 정규화를 이용한 다시기 적외 위성영상의 변화탐지, 대한원격탐사학회지, 제 33권, 6호, pp. 1179~1185.
- Bannari, A., Asalhi, H., and Teillet, P. M. (2002, June). Transformed difference vegetation index (TDVI) for vegetation cover mapping. In IEEE International geoscience and remote sensing symposium (Vol. 5, pp. 3053-3055). IEEE.
- Gitelson, A. A., Kaufman, Y. J., and Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. Remote sensing of Environment, 58(3), 289-298.
- Gitelson, A. A., Kaufman, Y. J., Stark, R., and Rundquist, D. (2002). Novel algorithms for remote estimation of vegetation fraction. Remote sensing of Environment, 80(1), 76-87.
- Haboudane, D., Miller, J. R., Tremblay, N., Zarco-Tejada, P. J., and Dextraze, L. (2002). Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. Remote sensing of

- environment, Vol. 81, No. 2-3, pp. 416-426.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). Remote sensing of environment, Vol. 25, No. 3, pp. 295-309.
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., and Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. Remote sensing of environment, Vol. 83, No. 1-2, pp. 195-213.
- Jensen, J. R. (2015), Introductory Digital Image Processing: A Remote Sensing Perspective (Pearson Series in Geographic Information Science) 4th Edition, Pearson; 4th edition (September 10, 2015) Pearson
- Jelínek, Z., Kumhálová, J., Chyba, J., Wohlmuthová, M., Madaras, M., and Kumhála, F. (2020), Landsat and Sentinel-2 images as a tool for the effective estimation of winter and spring cultivar growth and yield prediction in the Czech Republic. International Agrophysics, Vol. 34, No. 3, pp. 391-406.
- Kaufman, Y. J. and Tanre, D. (1992). Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. IEEE transactions on Geoscience and Remote Sensing, Vol. 30, No. 2, pp.261-270.
- Louhaichi, M., Borman, M. M., and Johnson, D. E. (2001). Spatially located platform and aerial photography for documentation of grazing impacts on wheat. Geocarto International, Vol. 16, No. 1, pp. 65-70.
- Rouse, J. W., Haas, R. H., Schell, J. A., and Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. NASA special publication, 351, pp. 309.
- Thiemann, S. and Kaufmann, H. (2000), Determination of chlorophyll content and trophic state of lakes using field spectrometer and IRS-1C satellite data in the Mecklenburg Lake District, Germany. Remote sensing of environment, Vol. 73, No. 2, pp. 227-235.
- Xue, J. and Su, B. (2017), Significant remote sensing vegetation indices: A review of developments and applications. Journal of sensors, 2017.
- Yang, Z., Willis, P., and Mueller, R. (2008, November). Impact of band-ratio enhanced AWIFS image to crop classification accuracy. In Proc. Pecora (Vol. 17, No. 1, pp. 1-11).

제7장

국토위성 기반 주제도(지표, 지형) 시범제작 및 기술 리뷰

-
1. 연구의 배경 목적
 2. 연구 내용
 3. 결론 및 기대효과

1. 연구의 배경 및 목적

국토위성은 현재 영상 단위의 산출물(L1R, L2R, L2G)만이 결정되어있으나, 국토위성의 폭넓은 활용을 위해 다양한 활용산출물의 생산이 필요하다. 위성영상을 제공하는 국내외 기관들은 위성영상의 제공뿐만 아니라 자료처리를 통해 영상으로부터 추출된 가공 정보를 제공함으로써 사용자의 즉각적인 활용을 가능하게 한다. 국가기상위성센터는 천리안 기상위성(GEO-KOMPSAT-2A, GK-2A)이 촬영한 영상을 기반으로 자료처리를 통해 토양수분 및 홍수, 가뭄 등의 활용산출물을 개발 중에 있으며, 미국 지질조사국(USGS)은 Landsat 위성의 활용산출물로서 지표수(Dynamic Surface Water Extent), 눈덮임 지수(Fractional Snow Covered Area), 연소지역(Burned Area), 증발산량(Evapotranspiration) 등을 제공하고 있다. 본 연구에서는 국토위성의 활용산출물 확장을 위해 제작 가능한 활용산출물(주제도)을 지표정보(surface)와 지형정보(terrain)로 나누어 검토한다. 지표정보의 경우 기존에 수행한 대분류 단위(임지·수계·농지·도시 및 주거지) 분류방안을 바탕으로 분류정확도 향상을 위해 대기보정 적용, 객체기반 분류기법을 적용한다. 지형정보의 경우 위성영상 기반 DTM/DSM의 제작 가능성 검토를 위해 DTM/DSM 제작 과정에서 고려되어야 할 스테레오 영상의 기하조건, 영상 매칭 알고리즘, 보간기법 등에 대해 살펴본다. 이후 「국토위성정보 수집 및 활용기술 개발(2018~2020)」 연구 사업을 통해 개발된 DSM/DTM 생성 S/W에 사용된 알고리즘을 분석하고자 한다.

2. 연구 내용

가. 위성영상 기반 지표정보 추출

1) 대분류 단위 분류 수행 결과

국토위성 기반 대분류 단위(임지·수계·농지·도시 및 주거지) 지표 정보의 추출 가능성을 검증하기 위해 대상지역을 농경지와 도심지로 나누었다. 임지·수계·농지를 포함하고 있는 전남 고흥지역과, 고층 건물이 많이 분포해있는 서울 양재 지역을 선정하였으며 모의영상인 KOMPSAT-3A 영상의 DN값을 radiance 값으로 변환하여 사용하였다. 항목 분류를 위해서는 육안분석, 밴드연산, 감독·무감독분류 등을 활용하였다.

가) 임지·수계·농지 분류

홍석영 외(2008)는 영상의 분류 정확도를 높이기 위해 각 항목을 분류한 결과를 제거하고, 앞서 분류한 결과를 제외한 나머지 영역에 대해서 재분류를 실시하는 단계별 분류 방법을 적용하였다. 이에 따라, 본 연구에서도 밴드연산(NDVI, NDWI)을 통해 임지와 수계를 먼저 분류하고, 이를 제외한 나머지 부분에 대해 무감독 분류(ISODATA)를 수행하여 농지를 분류하였다.

고흥지역을 촬영한 K3A 영상은 2017년 6월 2일 여름철에 촬영된 것으로, 산림의 활력도는 높지만 6월은 작물이 완전히 발달하지 않은 시기로 산지를 제외하고는 녹지가 많지 않다. 농촌지역은 비교적 단조로운 피복을 가지기 때문에 NDVI와 NDWI만으로 임지와 수계의 구분이 가능했다. 특히, 농지의 경우 NDVI map에서 논과 밭이 유사한 값을 가져 구분이 어려웠으나 ISODATA 분류 결과 논과 밭의 구분이 가능함을 확인하였다(그림 7-1).



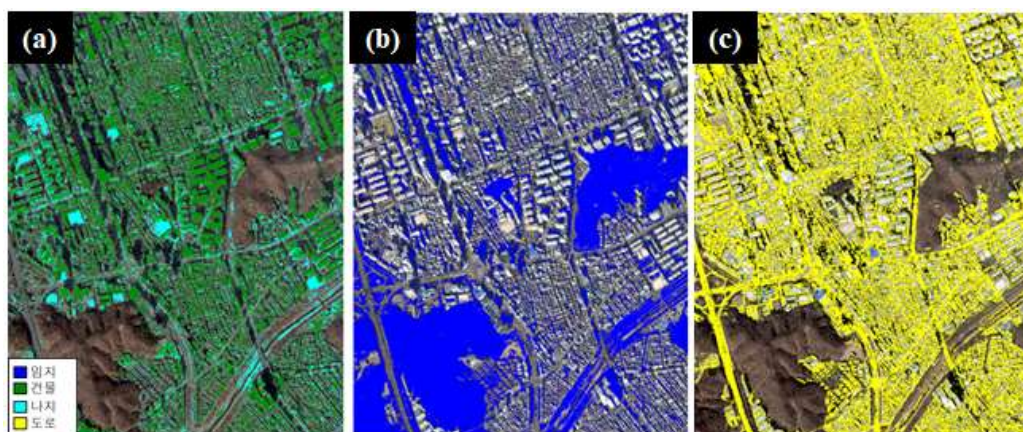
<그림 7-1> 위성영상 기반 농경지 분류 결과

나) 도시 및 주거지 분류

농경지에 비해 고층 건물, 건물에 의한 그림자, 도로 등 비교적 복잡한 토지이용을 갖고 있는 도심지 영상을 분류하기 위해서는 훈련자료를 이용해 분류 정확도를 높일 수 있는 감독분류를 활용하였다. 감독분류 알고리즘 중 하나인 MLC(Maximum Likelihood Classification) 기법을 사용하였으며, 클래스는 건물·나지·임지·도로로 구분하고 육안판단을 통해 훈련자료를 직접 제작하여 영상 분류를 수행하였다.

서울 양재지역을 촬영한 K3A 영상은 2016년 1월 8일 겨울철에 촬영된 영상이다. 영상 내 존재하는 수계 분류를 위해서는 앞의 농경지와 같이 NDWI map 기반 임계값을 적용하여 분류하고, 나머지 영역에 대해 감독분류를 수행하였다. NDWI 기반 수계 분류 결과, 농경지에서와 달리 고층 건물에 의한 그림자에서 발생한 오탐지가 존재하여 수계만의 분류가 어려웠다. 감독분류 결과 고층건

물의 경우 대부분 옳게 탐지하였으며, 저층 건물의 경우 옳게 탐지되는 부분도 있으나 건물이 차지하는 면적이 작아 어둡게 나타나는 저층 건물은 탐지되지 않았다. 나지의 경우 학교 운동장과 같이 눈에 띄는 나지는 모두 옳게 분류하였으며, 임지와 도로로 분류된 것 중에는 어두운 값을 가지는 그림자에서 오는 오탐지가 많았다.

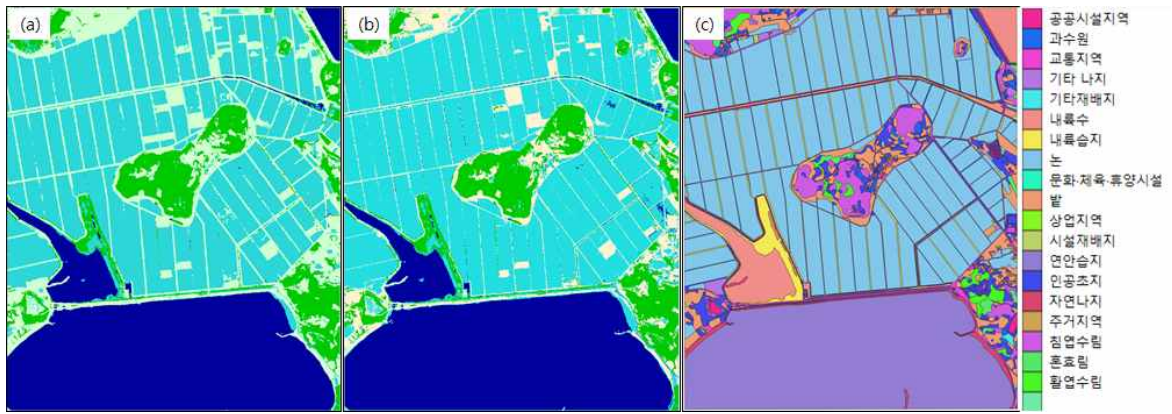


<그림 7-2> 위성영상 기반 도심지 분류 결과 (a)건물, 나지 (b)임지 (c)도로

2) 정확도 향상을 위한 기존 분류방안의 추가 실험

기존 분류방안을 바탕으로 분류 정확도를 향상시키기 위해 영상기반 대기보정을 수행하여 반사도(reflectance)로 변환하여 분류를 수행한다. 위성영상으로부터 토지피복 분류를 수행한 선행 연구들을 살펴보면 대기보정을 수행하여 반사도 값을 이용해 분류하였다(Kim and Yeom, 2012; Shin et al., 2015; 이승기 외, 2015; Lee and Lee, 2020). 이는 다중시기 영상을 사용하는 경우나 객체기반 분류를 수행하는 경우, 그리고 분류 자동화를 위한 공통 임계값 설정을 가능하게 한다는 장점이 있다.

전남 고흥을 촬영한 동일한 K3A 영상에 AR model을 활용하여 DN값을 reflectance값으로 변환한 뒤, 동일하게 NDVI와 NDWI를 이용하여 산림과 수계를 분류하고 무감독분류를 이용해 영상 전체를 분류하였다. 그 결과, <그림 7-3>과 같이 기존 분류한 결과와 전반적으로 비슷한 결과를 보여주지만, 기존에는 밭으로 분류되었던 농지 사이의 내륙수나 내륙습지가 다소 분류되는 결과를 보여주었다.

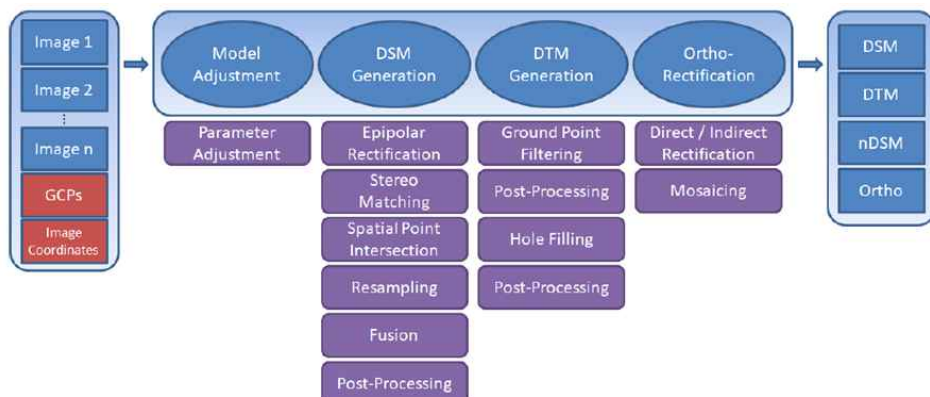


<그림 7-3> (a)기존 분류 결과 (b)대기보정 후 분류 결과 (c)토지피복지도

다. 국토위성 기반 지형정보

1) 위성영상 기반 DSM/DTM 제작


전통적으로 DSM/DTM은 LiDAR(Light Detection and Ranging) 측량 또는 항공사진 측량을 통해 제작된 수치지형도의 등고선을 이용하여 제작되어 왔다. 위성영상을 기반으로 제작하는 방법의 경우 항공촬영이 불가능한 지역의 DSM/DTM 제작이 가능하고, 기존의 방법에 비해 변화지역의 DSM/DTM을 갱신하는데 매우 유용하다는 장점이 있다. 스테레오 위성영상 기반 DSM/DTM은 <그림 7-4>와 같이 센서모델링을 통해 두 영상의 대응점들 사이의 기하학적 관계(epipolar)를 구성하여 두 영상 사이의 y시차를 제거한 후, 영상 매칭을 통해 대응점 중 정합대상으로 선정된 점들의 집합인 포인트 클라우드(point cloud)를 생성하고 높이값 보간 기법을 통한 격자화의 과정을 거쳐 제작된다(Kwon, 2019).



<그림 7-4> DSM/DTM 제작 과정(Perko, 2019)

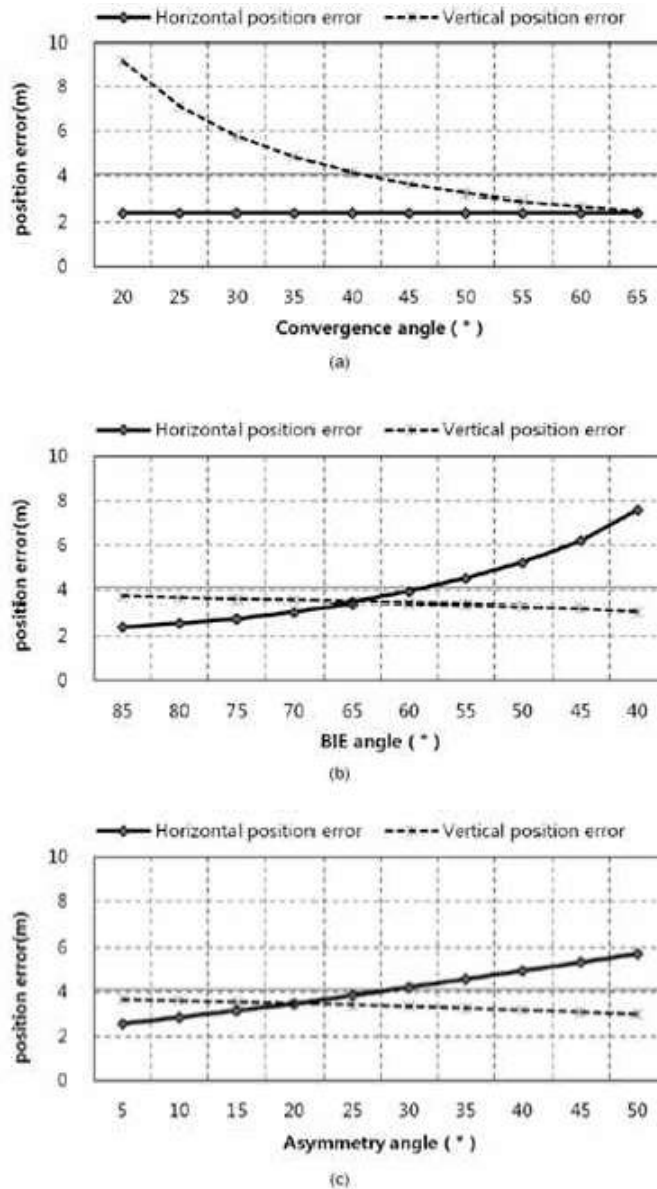
2) 스테레오 위성영상 기하수립

스테레오 영상으로부터 얻은 3차원 정보의 정확도를 결정하는 요인은 크게 2가지로, 스테레오를 구성하는 각 영상의 센서모델 정확도와 두 영상이 구성하는 스테레오 기하의 안정성이다(Jung, 2016). 국토위성의 경우 GCP chip을 이용해 센서모델링에 사용되는 계수의 모음인 rpc file이 업데이트된 L2R 영상을 제공하므로, 본 연구에서는 센서모델 부분은 제외하고 스테레오 영상의 촬영 기하에 대해 살펴보고자 한다. 스테레오 위성영상 획득 시 고려해야 하는 입체각에는 수렴각(convergence angle), 이등분선고도각(BIE, bisector elevation), 비대칭각(asymmetry angle) 등이 있으며(그림 7-5), 입체각의 구성에 따라 수평 및 수직 방향의 오차에 영향을 미치게 된다.



<그림 7-5> 스테레오 기하 구성(Jeong and Kim, 2016)

수렴각은 스테레오를 구성하는 두 센서의 촬영방향이 형성하는 평면 내에서 이루어지는 사잇각을 의미한다. 이등분선고도각은 해당 평면 내에서 수렴각을 이등분하는 선분이 지평선으로부터 얼마의 고도각을 갖고 있는지를 의미하며, 이는 곧 해당 평면의 기울기를 의미한다. 비대칭각은 스테레오를 구성하는 두 센서의 촬영방향 벡터의 비대칭성을 의미한다. 「극지역 공간정보 활용성 제고 방안 연구」에 따르면, 수렴각의 경우 수직 방향의 오차에 주로 큰 영향을 주게 되므로, 최소 30도 이상을 권장한다. 이등분선고도각과 비대칭각은 주로 수평 방향의 오차에 영향을 주는데, 이등분선고도각은 이상적으로 90도가 좋지만 70도 이상이 좋고, 비대칭각의 경우 10도 이하가 좋다(그림 7-6).



<그림 7-6> 촬영각에 따른 정확도(Jeong and Kim(2016))

3) 영상매칭(image matching)

DSM/DTM의 품질은 영상매칭을 통해 생성된 포인트 클라우드 품질에 좌우되므로, 이를 생성하는 매칭 기법과 보간기법의 사용이 중요하다(Rhee et al., 2020). 영상매칭은 시차(parallax, shift vector, disparity)를 찾는 과정으로, 기준점의 한 점에 대응하는 점을 타겟 영상에서 추출하는 것이다. 매칭 기법은 크게 공간영역과 주파수영역으로 나눌 수 있으며, 공간영역에서도 추출되는 밀도에 따라 dense matching(area-based)과 coarse matching(feature-based) 기법으로 나뉜다. 영역 기반(area-based) 매칭은 윈도우 커널을 사용하여 방사값을 기반으로 두 영상 사이의 상관계수를 계산하여 임계값 이상인 경우 매칭점으로 선택한다. 왜곡이 많지 않은 경우에 사용

하기 좋고, 상대적으로 방법이 간단하여 널리 사용되고 있다. 특징 기반(feature-based) 매칭은 엣지(edge)나 코너(corner), 질감(texture), 형태(shape) 등을 기반으로 특징점(feature point)을 추출하는 방법으로, 축척이나 회전변환 등 변화영역에 강한 성능을 보여 컴퓨터비전(computer vision) 분야에서 많이 사용되고 있다. 특징점 추출은 제한된 수의 접합점을 추출하는 경우에 사용하기 좋다.

공간영역에서 매칭 기술에 따라 분류하는 경우, Local(지역)매칭과 Global(전역)매칭으로 구분할 수 있다. Local 매칭은 영상 전체가 아닌 일부 영역에 대해서만 값을 비교하여 그 차이가 최소화되는 점을 정합점으로 선택한다. Global 매칭은 두 영상 사이의 에피폴라 라인 전체의 정합에너지를 최소화하는 점, 즉 에피폴라 라인의 모든 점에 대해 최적화된 시차 값을 구하여 정합점을 선택한다. 많은 연구에서 상관계수 기반의 NCC(Normalized Cross Correlation)를 주로 사용하고 있으며(Oh et al., 2018), 원 영상으로부터 영상 피라미드를 추출하는 피라미드 방식(Poli et al., 2004)과 이외에도 ICP(Iterative Closest point)(Oh and Lee, 2017), SGM(Semi-Global Mathching)(Kwon, 2019) 방식 등이 활용되고 있다. 이 중, SGM 방식은 에피폴라 라인 상에서 대상 픽셀을 중심으로 8방향 또는 16방향의 픽셀 값만 고려하여 정합비용을 계산한다. 이에 따라, Local 매칭에 비해 정확도가 높은 Global 매칭의 장점은 확보하고, 8방향의 픽셀만 고려한다는 점에서 오랜 처리 시간이 소요되는 Global 매칭에 비해 처리 속도를 향상시켜, 다른 알고리즘과 비교하여 처리결과 및 연산속도 측면에서도 우수한 성능을 보여 많이 사용되고 있다. ERDAS, PCI Geomatica, Trimble 등 대부분의 상용 S/W에서도 SGM 방식을 사용하고 있다(Perko, 2019).

4) 보간기법

생성된 3d point cloud를 격자화하기 위해서 높이값의 보간이 필요하며, 이상치를 제거하거나 비어있는 부분을 채우는 경우 보간 및 필터링 기법이 활용된다. 대표적인 보간 기법으로는 TIN(Triangulated Irregular Network), NN(Nearest Neighbor) 기법, IDW(Inverse Distance Weight) 기법, Kriging 기법 등이 사용된다. TIN은 불규칙삼각망을 구성하여, 삼각형 평면으로부터 선형 근사하여 표고값을 결정하며, NN은 해당 픽셀의 중심에서 가장 가까운 거리에 있는 점을 표고값으로 결정한다. IDW와 Kriging은 구하고자 하는 점으로부터 거리에 따라 가중치를 부여한다는 점이 유사하지만, Kriging은 거리뿐만 아니라 주위 점들 사이의 상관관계도 고려한다는 점이 다르다. 염승훈과 최재완(2018)에 따르면, 보간기법에 따른 DSM 결과는 평지나 완만한 경사에서는 차이가 없지만, 급격한 높이 차이를 보이는 건물이나 수목 등에서 차이가 나타난다고 하였다. 이에 따라, 적절한 보간기법의 사용이 필요하다.

5) DTM 생성

DSM으로부터 건물 및 수목 등 인공지물을 제거하여 지형정보만을 포함하는 DTM을 제작할 수 있다. 비지면 객체를 제거하기 위해 추출하는 방법으로는 기울기 기반 계산, 모폴로지 기법, 불규칙 삼각망(TIN) 생성 기반 등의 기법이 주로 사용된다(안희란과 김태정, 2019). 기울기 기반의 계산은 한 점과 일정 거리의 영역에 있는 점들과 비교하여 임계값 이상의 경사가 있는 경우 그 점을 비지면 점으로 인식하여 제거한다(Vosselman, 2000). 모폴로지 기법은 자료의 형태학적 특성을 이용하는 방법으로 침식(erosion)과 팽창(dilation) 연산을 사용한다. 침식은 영상을 깎아내기, 팽창은 주변으로 확장하는 연산이다. 침식을 적용한 후에 팽창연산을 수행하는 방법을 제거(opening) 연산, 팽창 적용 후 침식연산을 수행하는 방법을 채움(closing) 연산이라 한다. 비지면점을 제거하기 위해 제거연산을 적용하거나, 다양한 크기의 개체를 효과적으로 제거하기 위해 모폴로지 필터의 크기를 바꿔가며 반복 적용할 수 있다(Zhang et al., 2003). 불규칙삼각망을 이용하는 방법은 일정 영역 안에서 최소 높이값을 갖는 점으로부터 삼각망을 생성하고 지표면 조건에 해당하는 점을 차츰 추가하여 비지면점을 제거하게 된다.

6) DSM/DTM 생성 S/W 알고리즘 리뷰

「국토위성정보 수집 및 활용기술 개발(2018~2020)」 연구사업(이하 “R&D 사업”)에서 개발된 DSM/DTM 생성 S/W에서는 피라미드 방식을 활용하여 영상매칭을 수행하였으며, 입력 영상 GSD의 4배수까지의 격자간격을 생성할 수 있다. 포인트 클라우드로부터 DSM을 생성한 뒤, 모폴로지 기법(Geodesic dilation)을 통해 비지면점을 추출 및 제거하여 DTM을 제작하는 방식으로, 각 과정에 사용된 알고리즘을 살펴보고자 한다.

해당 연구사업에서는 입체기하를 수립하는 부분과 영상매칭 과정이 개발되었다. 입체기하수립에서는 선형 CCD를 사용하는 센서에 맞는 에피폴라 기하수립 방안을 도출하였다. 선형 CCD 센서를 사용하는 위성영상은 스캔 라인마다 서로 다른 외부표정요소(EO)를 갖고 있기 때문에 에피폴라 라인이 직선이 아닌 곡선 형태로 유도된다 (Gupta and Hartley, 1997; Kim, 2000). 이에 따라, 에피폴라 커브를 분석하고 기하 변환식을 구성하여 선형 재배열하여 입체영상을 제작하는 알고리즘을 개발하였다. 영상매칭 기술 개발에서는 피라미드 방식을 적용하여 영상매칭을 수행하였다. 피라미드 방식은 원 영상을 1/2, 1/4, 1/8 등으로 축소한 뒤, 가장 많이 축소된 영상에서 얻은 정합점을 다음 축소 영상의 정합 후보점으로 사용하는 것으로 영상매칭 정확도와 속도를 향상시킬 수 있다는 장점이 있다. 축소된 각 영상에서는 정합점을 얻을 때, 17*17에서 5*5까지의 다중탐색윈도우를 이용하여 상관계수를 계산하게 된다. 최종 형성된 3d point를 격자화하고, 생성된 DSM을 보간하기 위해서 IDW 기법이 사용되었다.

7) 국토위성 기반 DTM 평가

국토위성으로 촬영한 서울지역 스테레오 영상(L2R)을 입력자료로 하여 R&D 사업에서 개발된 DSM/DTM 생성 S/W를 통해 DSM과 DTM을 제작하였으며, 이 중 DTM(이하 “CAS500 DTM”)을 국토지리정보원 전국 5m DEM(이하 “NGII DEM”)과 비교하여 평가하고자 한다. 사용된 국토 위성 스테레오 영상에 대한 정보는 <표 7-1>과 같다. 두 영상의 촬영기하를 살펴보면 convergence angle은 약 49도로 앞에서 제시한 기준(30~50도)에 부합하지만, BIE는 약 61도로 앞에서 제시한 기준(70도 이상)을 만족하지는 않는다.

<표 7-1> 국토위성 스테레오 영상 정보

촬영지역	영상 ID	촬영일	Level	Roll(Deg.)	Pitch(Deg.)
서울 양재	C1_20211025015356_03297_00310919	2021.10.24.	L2R	18.558	1.011
	C1_20211024021358_03282_00179599	2021.10.25.	L2R	-26.689	-1.062

CAS500 DTM은 NGII DEM과 동일한 GSD(5m)로 제작되었으며, 스테레오 영상의 중복영역 중 1/5,000 크기에서 100% 중복되는 영역에 한해 DTM을 생산하였다. 총 7도엽이 생성되었고, 약 35분의 처리시간이 소요되었다. <표 7-2>와 같이 두 데이터의 좌표계가 서로 다르고, 높이값 표현 기준이 다르기 때문에 차분을 통한 상대비교를 하기 위해 두 데이터의 좌표계를 UTM으로 일치시키고, 높이값의 표현 기준을 KNGeoid18을 이용해 정표고로 일치시켜주는 전처리를 수행하였다.

<표 7-2> CAS500 DTM 및 NGII DEM 정보

	CAS500 DTM	NGII DEM
GSD for x(m)	5	5
GSD for y(m)	5	5
좌표계	UTM-K	TM
높이	타원체고	정표고

먼저 생성된 CAS500 DTM에 대해 육안분석을 수행하였다. CAS500 DTM에서 도엽 테두리를 따라 약 8~9픽셀 정도의 뭉개진 현상이 나타나는데, 이는 DSM으로부터 비지면점을 제거한 후 빈 부분(hole)의 보간을 위해 영상 전체에 적용된 필터링으로 인해 발생하며, 이에 대한 개선이 필요

한 것으로 판단된다. 또한, NGII DEM에 비해 건물의 흔적이 존재하는데 이 또한 DSM으로부터 비 지면점을 제거할 때 낮은 건물의 경우 완전한 언덕으로 인식되어 제거되지 않거나, 고층건물의 경우 제거되더라도 이후의 보간 과정에서 원활한 필터링이 이루어지지 않은 것으로 추정할 수 있다. CAS500 DSM의 오류로 인해 CAS500 DTM에도 오류가 나타나는 경우가 있었는데, <그림 7-7>과 같이 CAS500 DSM에서 하천지역을 제대로 생성하지 못해 CAS500 DTM에서도 해당 오류가 반영되었다.

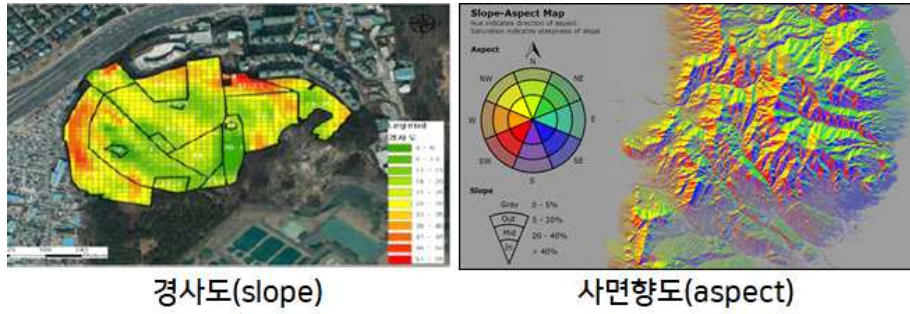


<그림 7-7> DSM의 하천 표현 오류로 인한 DTM 오류

생성된 7도엽 중, 6도엽에 대해 NGII DEM을 참값으로 놓고 차분을 통해 상대비교를 수행하였다. 5개 도엽이 평균 1m 이내, RMSD(Root Mean Square Difference, 높이값 잔차 제곱의 평균에 루트값) 2~4m를 가졌으며, 1개 도엽은 평균 약 4.8m, RMSD 약 6.8m의 차이를 가졌다. 대부분 산의 능선을 따라 높이 값의 차이가 약 2m~9m 정도가 있었으며, 건물지역은 대부분 약 1m이내를 보였다.

라. 그 외 지형관련 주제도(경사도)

DTM/DSM을 기반으로 생성될 수 있는 지형관련 주제도로 경사도와 사면향도를 고려해볼 수 있다(그림 7-8). 경사도와 사면향도는 국토분야 뿐만 아니라 수자원, 산림, 환경, 건축 등 다양한 분야에서 활용되고 있는 정보이다. 본 절에서는 경사도를 중심으로 경사도 제작에 사용되는 알고리즘과 토지 분야의 행정업무를 위해 법령에서 정의하는 경사도 제작 방법을 살펴보고자 한다.



<그림 7-8> 경사도 및 사면향도 예시

일반적으로 경사도 계산에 많이 사용되는 알고리즘은 Neighborhood로, 이는 ESRI 社의 공간 분석 프로그램인 ArcGIS의 경사도 분석방법이기도 하다. Neighborhood 알고리즘은 DEM에서 대상 픽셀을 중심으로 8방향의 픽셀 값을 사용하여 식 (1)을 통해 경사도를 계산한다.

$$S(\text{degree}) = A \tan(\sqrt{(dz/dx)^2 + (dz/dy)^2}) \times 57.29578$$

$$dz/dx = \frac{(Z_3 + 2Z_4 + Z_5) - (Z_1 + 2Z_8 + Z_7)}{8 \times d}$$

$$dz/dy = \frac{(Z_1 + 2Z_2 + Z_3) - (Z_7 + 2Z_6 + Z_5)}{8 \times d}$$

Z ₁	Z ₂	Z ₃
Z ₈	Z ₉	Z ₄
Z ₇	Z ₆	Z ₅

(1)

S : 경사도, d : DEM 해상도, Z_i : i 번째 픽셀 값(높이)

Neighborhood 알고리즘은 완만한 경사도를 나타내기 때문에 고저특성이 있는 지형에 적용하기에 적합한 것으로 알려져 있다 (이창환과 성춘자, 2016). 그러나 특정 방향의 급경사가 표현되지 않거나 평균화되어 스무딩되는 효과가 발생하기도 한다 (고석민 외, 2014). 이외에도 Quadratic Surface, Maximum Slope 등의 방법을 통해 경사도를 계산할 수 있다 (An et al., 2005). Quadratic Surface 알고리즘의 기본 개념은 Neighborhood 알고리즘과 같지만, 8방향의 픽셀 값을 사용하는 Neighborhood와 달리 대상 픽셀을 중심으로 동서남북 4방향의 픽셀 값만 사용하여 경사도를 계산한다. Maximum Slope은 식 (2)와 같이 대상 픽셀을 중심으로 8방향의 픽셀과의 경사도를 계산하고, 그 중 최대 경사 값을 대표 경사 값으로 표현한다.

$$S(\text{degree}) = A \tan(\max \left| \frac{Z_9 - Z_i}{L_i} \right|) \times 57.29578$$
(2)

다음으로는, 행정업무에서 사용되는 경사도 산정 방법을 살펴보기 위해, ‘경사도’가 언급되는 법령(국토교통부 소관)을 검색하였고, 22개 법령이 국토의 계획, 토지평가, 시설물 설치 등을 위해 경사도를 고려하도록 규정되어있다. 이 중, 토지의 경사도를 산정하는 방법에 대해 언급된 법령은 「

국토의 계획 및 이용에 관한 법률(국토계획법)』로, 같은 법 시행규칙에서 개발행위허가기준을 위한 경사도 산정 방법을 구체적으로 명시하고 있다. 기존에는 수평거리와 고저차를 이용하여 경사각을 산정하는 방법이었으나, '16년 국토계획법 시행규칙이 개정됨에 따라 「산지관리법 시행규칙」에 따른 평균경사도 측정방법을 이용한 평균경사도를 산정방법으로 변경되었다(김현영 외, 2018). 「산지관리법」에 따른 평균경사도 측정은 1/50,000이상 1/1,000 이하의 수치지형도를 이용한다. 10m×10m 격자를 설정하여 불규칙삼각망(TIN)을 생성한 후, 격자 내 삼각면의 경사와 면적을 계산하여 평균경사도를 산출한다. 그러나 수치지형도가 없거나 자연재난 및 개발행위로 인해 지형이 급격히 변해 해당 지역의 수치지형도가 현실과 맞지 않는 경우에는 「수치지도 작성 작업규칙」에 따라 작성한 수치지형도를 이용해 평균경사도를 산정하도록 되어있다. 또한, 개별공시지가 조사·산정을 위해 국토교통부에서 작성한 지침에서 '고저' 특성을 저지, 평지, 완경사, 급경사, 고지로 분류하였으나, 구체적인 경사도 산정방법에 대해 언급하지 않고 있다.

3. 결론 및 기대효과

본 연구에서는 국토위성 기반 지표 및 지형 정보 주제도의 제작 가능한 주제도의 대상, 범위, 기술, 그리고 추가로 개발이 필요한 기술 등이 도출됨으로써, 국토위성의 활용산출물 확장을 위한 근거 자료로 활용할 수 있다. 먼저, 지표정보의 경우 도심지와 농경지 시범제작을 통해 분류 항목별 구축 가능한 기술, 분류 가능한 대·중·세분류 단위, 지역 특징에 따른 고려사항이 도출되어 향후 주제도의 정규 산출물 제작을 위한 기획연구 시 반영하고자 한다.

입체영상 구성을 위한 스테레오 기하조건 리뷰를 통해 DSM/DTM의 3차원 정보 생성을 위한 입력영상을 선정할 수 있다. 현재는 국토위성 1호기만 발사된 상황으로 입체영상을 얻기 위해서는 pitch tilt를 통한 in-track 운용이 필요하나 국토위성의 경우 단시간 내에 pitch tilt 기동이 어렵다. 이러한 점을 고려하여 서로 다른 시기에 획득된 두 영상을 스테레오 영상으로 사용할 수 있는데, 이 때 본 연구에서 도출된 스테레오 기하조건 리뷰가 두 영상의 선정기준이 될 수 있다. 또한, 향후 국토위성 2호기가 발사되는 경우 roll tilt를 통한 cross-track 운용을 바탕으로 스테레오 영상을 얻을 수 있으므로, 스테레오 영상 획득을 위한 촬영계획 수립에 반영할 수 있다.

마지막으로, DSM/DTM 제작을 위한 영상매칭 알고리즘 별 특징과 R&D 사업에서 개발된 DSM/DTM 생성 S/W에 사용된 제작 알고리즘을 살펴보았다. 국토위성 스테레오 영상을 사용해 해당 S/W를 기반으로 DSM/DTM을 제작하고 육안분석 및 NGII DEM과의 비교평가를 수행하였다. 현재 DSM/DTM 생성 S/W에서 생성되는 산출물에 대한 분석을 바탕으로 향후 DSM/DTM의 정규산출물화를 위해 개선 및 고도화가 필요할 것으로 판단된다.

참고문헌

- 고석민, 이승우, 윤찬영, & 김기홍. (2014). 우면산 산사태 발생 지점의 지형분석. 한국측량학회지, 32(1), 55-62.
- 김현영, 김문기, 고준환, & 지종덕. (2018). 고저·경사도 관련 연구동향 분석. 대한공간정보학회 학술대회, 211-215.
- 안희란, & 김태정. (2019). 저해상도 지형 자료를 활용한 KOMPSAT-3A 스테레오 영상 기반의 DTM 생성 방법. 대한원격탐사학회지, 35(5), 715-726.
- 염승훈, & 최재완. (2018). 촬영조건 및 전처리에 따른 UAV 기반 정사영상 및 DSM 의 품질평가. 건설기술논문집, 37(2), 15-20.
- 이금삼, & 조화룡. (2000). DEM 을 이용한 한반도 지형의 경사도 분석. 한국지리정보학회지, 3(1), 35-43.
- 이승기, 최석근, 노신타, 임노열, & 최주원. (2015). 국가토지피복도와 무감독분류를 이용한 초기 훈련자료 자동추출과 토지피복지도 갱신. 한국측량학회지, 33(4), 267-275.
- 이창한, & 성춘자. (2016). 고저특성의 평가를 위한 경사도 알고리즘 비교 분석. 대한공간정보학회 학술대회, 239-240.
- 홍석영, 임상규, 이승호, 이정철, & 김이현. (2008). 위성영상을 이용한 북한의 농업환경 분석 -I. Landsat TM 영상을 이용한 북한의 지형과 토지피복분류. 한국환경농학회지, 27(2), 120-132.
- Duro, D. C., Franklin, S. E., & Dubé, M. G. (2012). A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. Remote sensing of environment, 118, 259-272.
- Gupta, R., & Hartley, R. I. (1997). Linear pushbroom cameras. IEEE Transactions on pattern analysis and machine intelligence, 19(9), 963-975.
- Hudson, G. D. (1936). The unit area method of land classification. Annals of the Association of American Geographers, 26(2), 99-112.
- Jeong, J., & Kim, T. (2016). Quantitative estimation and validation of the effects of the convergence, bisector elevation, and asymmetry angles on the positioning accuracies of satellite stereo pairs. Photogrammetric Engineering & Remote Sensing, 82(8), 625-633.
- Kim, H. O., & Yeom, J. M. (2012). A study on object-based image analysis methods

- for land cover classification in agricultural areas. *Journal of the Korean association of geographic information studies*, 15(4), 26-41.
- Kim, T. (2000). A study on the epipolarity of linear pushbroom images. *Photogrammetric engineering and remote sensing*, 66(8), 961-966.
- Kwon, W. (2019). DSM generation and accuracy comparison using stereo matching based on image segmentation. *Korean Journal of Remote Sensing*, 35(3), 401-413.
- Lee, S. H., & Lee, M. J. (2020). A Study on Deep Learning Optimization by Land Cover Classification Item Using Satellite Imagery. *Korean Journal of Remote Sensing*, 36(6_2), 1591-1604.
- Oh, K. Y., Jeong, E. C., Lee, K. J., Kim, Y. S., & Lee, W. J. (2018). Comparison and analysis of matching DEM using KOMPSAT-3 in/cross-track stereo pair. *Korean Journal of Remote Sensing*, 34(6_3), 1445-1456.
- Oh, J. H., & Lee, C. N. (2017). Accuracy assessment of topographic volume estimation using kompsat-3 and 3-A stereo data. *한국측량학회지*, 35(4), 261-267.
- Oh, K. Y., Hwang, J. I., Yoo, W. S., & Lee, K. J. (2020). Performance Evaluation of KOMPSAT-3 Satellite DSM in Overseas Testbed Area. *Korean Journal of Remote Sensing*, 36(6_2), 1615-1627.
- Perko, R., Raggam, H., & Roth, P. M. (2019). Mapping with pléiades—end-to-end workflow. *Remote Sensing*, 11(17), 2052.
- Poli, D., Zhang, L., & Gruen, A. (2004). SPOT-5/HRS stereo images orientation and automated DSM generation. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 35(B1), 421-432.
- Rhee, S., Jung, S., & Park, J. (2020). 1: 5000 Scale DSM Extraction for Non-approach Area from Stereo Strip Satellite Imagery. *Korean Journal of Remote Sensing*, 36(5_2), 949-959.
- Shin, J. S., Lee, T. H., Jung, P. M., & Kwon, H. S. (2015). A study on land cover map of UAV imagery using an object-based classification method. *Journal of Korean Society for Geospatial Information System*, 23(4), 25-33.
- Vosselman, G. (2000). Slope based filtering of laser altimetry data. *International archives of photogrammetry and remote sensing*, 33(B3/2; PART 3), 935-942.
- Zhang, K., Chen, S. C., Whitman, D., Shyu, M. L., Yan, J., & Zhang, C. (2003). A progressive morphological filter for removing nonground measurements from airborne LIDAR data. *IEEE transactions on geoscience and remote sensing*, 41(4), 872-882.

제8장

영상분석 기술을 활용한 재난 분석

1. 연구의 배경 및 목적
2. 주요 내용
3. 결론 및 기대효과

1. 연구의 배경 및 목적

국토위성센터는 긴급 공간정보 서비스(긴급 공간정보)를 제공을 통해 재난 안전 관리에 효율적으로 대응하고 객관적 정책결정을 지원하고자 한다. 긴급 공간정보는 위성 및 공간정보를 신속하게 취득·가공하여 사용자에게 제공하는 서비스이며, 본 연구에서는 재난발생시 피해 영역을 효과적으로 탐지하는 방법을 연구하였다. '20년도에 추진한 프로토타입 구축 연구에서는 긴급 공간정보 서비스의 첫 제공 사례인 안동산불('20.4월)을 대상으로 다출처 영상자료(항공, 위성, 드론) 기반의 '다중플랫폼 기반 이종영상 융합 및 변화탐지 사례연구(산불)'를 수행하여 자료의 융합 방안과 가능성을 확인하고 위성영상 종류(Landsat, Kompsat, Planet Scope)에 따른 산불 피해범위를 탐지하였다. 본 연구에서는 산불 뿐 아니라 다양한 재난유형(침수, 산사태, 대설 등)으로 대상을 확대하고 재난발생 지역특성 및 가용 위성센서(광학/SAR) 등을 고려하여 신속한 피해범위를 탐지하는 방법을 도출하고자 한다.

2. 주요 내용

가. 대응재난 선정 및 재난유형별 분석 방법 도출

행정안전부에서 매년 발간하는 자연재해통계(재해연보)와 사회재난통계(재난연감)을 활용하여 재난종류별 과거의 재난 발생현황을 살펴보았다. 재해연보는 자연재난(폭염, 태풍, 호우, 대설, 지진 등)의 피해 및 복구 현황에 대한 주요 통계를 담고 있으며 당해 연도의 국내 자연재해 발생현황, 복구비 지원내역 통계, 최근 10년간 재해 상황 통계 등을 제공한다. 재난연감은 사회재난(산불, 유해화학물질 유출사고, 댐 붕괴 등)의 사고발생현황 및 중앙·지역 재난안전대책본부 운영 현황 등에 대한 통계 정보를 제공하고 있다. 재해·재난 통계정보를 참고하여 과거 우리나라에서 발생한 자연재난 및 사회재난의 발생현황과 추세를 살펴보고 위성영상을 활용한 재난피해 탐지 가능성을 분석하여 본 연구에서 시범적용을 위한 재난을 계절별로 다음과 같이 선정하였다.

① 봄·가을철 : 산불, ② 여름철 : 풍수해, ③ 겨울철 : 대설

또한 계절별 발생한 재난 중 시범적용을 위한 재난 사례를 선정하기 위하여 재난 및 안전관리 기

본법에서 정의하는 재난분야 위기관리 매뉴얼(위기관리 표준매뉴얼, 위기대응 실무매뉴얼, 현장조치 행동매뉴얼)을 살펴보고 대규모 재난 피해가 예상 되는 재난기준 및 지자체 등에서 활용하기 위한 최종산출물 형태를 검토하여 표 8-1에 제시하였다.

각각의 재난 특성을 고려하여 적용 가능한 알고리즘(지수)을 선정하고, 신속하게 피해 범위를 탐지 할 수 있는 방법인 통계적 패턴분류(무감독 분류) 기법 등을 피해범위 탐지 방법으로 선정하였다. 활용위성으로는 광학위성을 기반으로 피해 탐지를 수행하며 풍수해의 경우 구름 등에 의해 피해 지역파악이 어려울 수 있으므로 SAR 위성영상을 추가적으로 활용하고자 한다.

<표 8-1> 시범적용 재난 및 연구대상 선정기준

재난유형	① 산불	② 풍수해	③ 대설
대책기간	2.1~5.31 (3.13~4.18)	5.15~10.15	11.15~다음해 3.15
대응기준 (위기관리 표준매뉴얼)	대형산불: 피해면적 100ha, 24시간 이상 지속	태풍 및 호우 경보*가 발령되 고 침수피해가 감지될 때	대설주의보: 24시간 신적설이 5cm 이상 대설경보: 24시간 신적설이 20cm 이상 예상될 때
재난특성	단기/장기	단기	단기
산출물	산림 피해 예상영역	침수 피해 예상영역	대설 피해 예상영역
피해탐지 방법(지수)	· 식생지수(NDVI) · 탄화지수(NBR) · 무감독 분류	· 광학: 수분지수(NDWI) · SAR: 전·후 영상 중첩	· BQA밴드 · 강설지수(NDSI) · 빙하지수(NDGI)
알고리즘(지수) 계산식	$NDVI = \frac{NIR - RED}{NIR + RED}$ $NBR = \frac{NIR - SWIR}{NIR + SWIR}$	$NDWI = \frac{GREEN - NIR}{GREEN + NIR}$	$NDSI = \frac{GREEN - SWIR}{GREEN + SWIR}$ $NDGI = \frac{GREEN - RED}{GREEN + RED}$
활용위성	광학위성(Landsat-8)	광학위성 (Landsat-8, Sentinel-2) SAR위성(Sentinel-1)	광학위성(Landsat-8, Sentinel-2)
국토위성 적용가능성**	O	O	X

* 태풍경보 : 풍속이 17m/s 이상, 또는 강우량이 100mm 이상, 호우경보 : 3시간 강우량이 90mm 또는 12시간 강우량이 180mm 이상

** 국토위성은 RED, GREEN, BLUE, NIR 4개 밴드를 갖고 있으며, SWIR 밴드가 필요한 지수는 적용 불가

나. 봄·가을철 산불 대응을 위한 영상분석

1) 산불 대응을 위한 영상분석 대상 및 방법

산불통계연보(산림청, 2021)의 통계자료에 따르면 최근 10년간 100ha 이상 산불피해 발생은 총 16건으로 주로 강원도 및 경상북도에서 3월~5월 사이에 많이 발생하였다. 과거 사례 중 산불이 발생한 지역적 특성을 고려하여 연구지역으로 ① 산림지역: 경상북도 안동시('20.04), ② 해안지역: 강원도 고성군('18.03) ③ 도심지역: 울산광역시 울주군('13.03)을 시범지역으로 선정하였고, 산불 발생 시점부터 복구될 때까지의 장기간 모니터링을 수행하고자 한다. Landsat-8 위성영상에서 구름의 영향이 적고 산불 피해 영역이 육안으로 관측되는 지역을 검토하여 가용 가능한 Landsat 영상을 수집하였으며 표 8-2에 제시한 것과 같이 산불 전·후의 영상뿐만 아니라 산불이 발생한 1년 후, 그리고 2021년 최신 영상을 확보하였다.

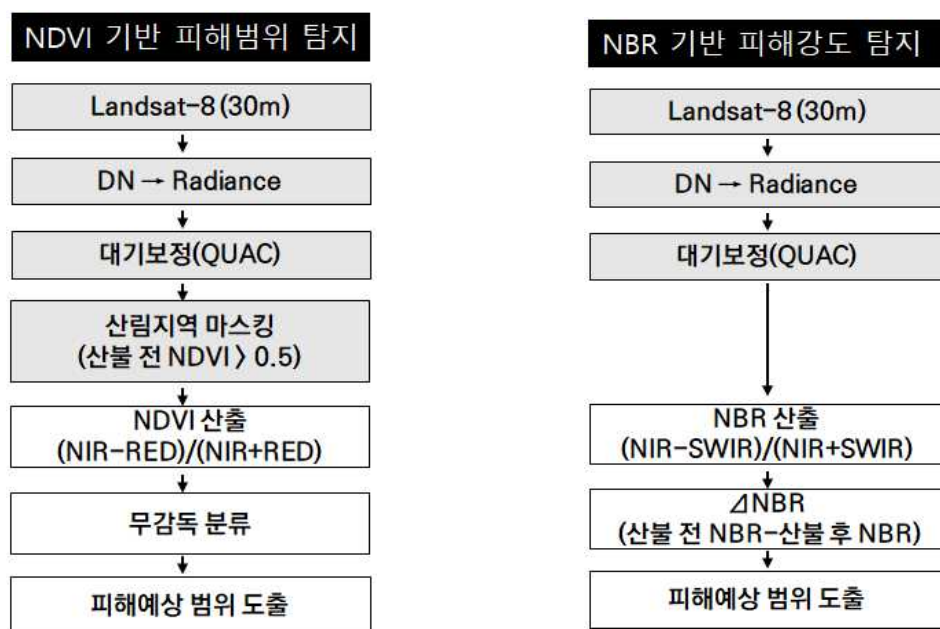
<표 8-2> 수집 영상 정보

연구지역	산불발생일	촬영일	위성영상
경상북도 안동시	2020.04.24	(발생 전) 2020.04.14	Landsat 8 (30m 해상도)
		(산불 후) 2020.04.30	
		(1년 후) 2021.04.17	
강원도 고성군	2018.03.28	(발생 전) 2018.02.11	
		(산불 후) 2018.04.05	
		(1년 후) 2019.04.03	
		(최신영상) 2021.03.23	
울산광역시 울주군	2013.03.09	(발생 전) 2013.03.02	
		(산불 후) 2013.05.13	
		(1년 후) 2014.05.16	
		(최신영상) 2021.05.19	

관심지역 별 Landsat-8 위성영상 취득, 영상 전처리(방사보정, QUAC 대기보정) 과정이 공통 영상처리 과정으로 수행되고, 산불 피해지역 탐지에 유용한 지수인 정규식생지수(NDVI, Normalized Difference Vegetation Index)와 정규탄화지수(NBR, Normalized Burn Ratio)를 적용하였다. NDVI 지수에 대해서는 임계값을 적용하는 방법, 영상분류 방법을 적용하였고 NBR 지수에는 재난 발생 전·후 영상의 지수산정 결과를 차분하는 방법을 적용하여 산림피해 변화 모니터링을 수행하였다. 그림 8-1은 산불 피해지역 탐지를 위한 연구흐름도이며, 모든 분석은 ENVI 5.5.3을 이용하여 처리하였다.

NDVI는 식생이 적외선(REDF) 파장대는 강하게 흡수하는 반면 근적외선(NIR, Near-Infrared) 파장대는 반사하는 특성을 이용하여 식생 상태를 파악 할 수 있는 지수이다. 20년도에 수행한 경험적 임계값($NDVI < 0.35$) 적용 이외에 추가적으로 NDVI 결과에 통계적 분류 방법을 적용하여 산불 피해 범위 탐지 가능성을 살펴보고자 한다. 경험적 임계값은 계절적 영향, 지역 특성 등에 의해 변할 수 있기 때문에 NDVI 통계적 특성으로 피해 영역을 분류할 수 있도록 무감독 분류 방법을 추가로 적용하였다. NBR 지수는 식생에 민감한 근적외선(NIR)와 토양수분에 민감한 중적외선(SWIR, Short-Wave Infrared) 파장대를 이용하여 산불 발생영역을 탐지할 수 있으며 특히 피해강도별 산불 피해지역을 탐지하는데 효과적이다. 산불 피해 전·후 영상에서 각각 NBR 지수를 계산한 다음 산불 전 NBR - 산불 후 NBR 계산(ΔNBR)을 통해 산불로 인한 피해 정도를 파악하고자 한다(원명수 외(2007)),

<그림 8-1> 봄·가을철 산불 피해 탐지 흐름도

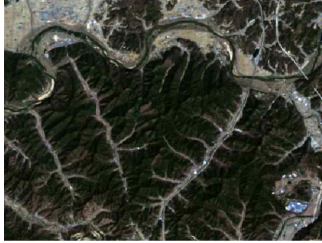







2) 산불피해 모니터링 결과

가) 경상북도 안동시 산불피해(20년 4월)

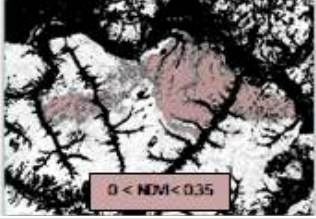
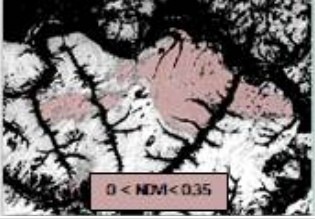
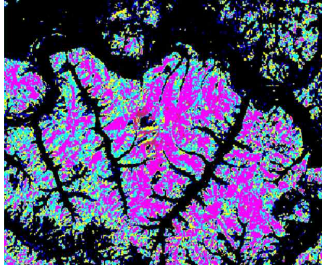
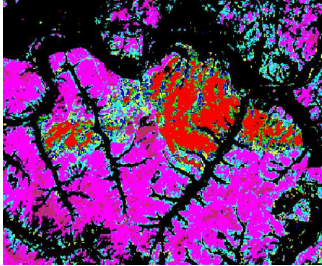
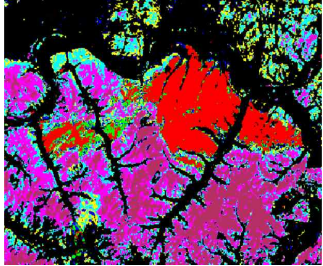
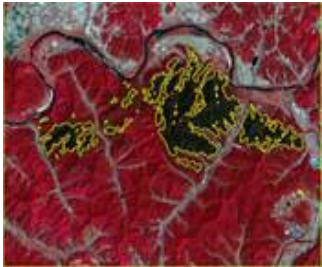


가장 최근 발생한 경상북도 안동시 산불(20년 4월)은 야산에서 발생하여 약 1,944ha 이상이 소실된 산림지역에 발생한 대표적인 대형 산불 사례이다. 표 8-3에서 제시한 RGB(Red-Green-Blue) 및 CIR(Color-infrared, NIR-RED-GREEN) 합성 영상을 통해 기존 산림지역과 피해지역이 뚜렷이 구분됨을 확인할 수 있다.

<표 8-3> 경상북도 안동시 산불발생 지역

합성 영상	발생 전(20.4.14)	산불 후(20.4.30)	산불 +1년 후
RGB 영상			
CIR 영상			

NDVI 지수를 이용한 산림지역의 산불 피해범위 탐지 결과는 표 8-4와 같다. 산불 발생 직후 및 1년 후의 피해를 모니터링하기 위하여 산림지역만을 대상으로 각각 NDVI를 산출하고 육안으로 산불 피해지역으로 파악되는 경험적 임계값($NDVI < 0.35$)을 적용(Taufik et al., 2016)하여 피해 범위를 탐지 하였으나, 표 8-4와 임계값 결과에서 확인할 수 있듯이, NDVI 임계값으로는 두 영상 간 피해영역의 차이를 확인할 수 없었다. 산림은 계절적 영향, 지역 특성 등에 의해 변할 수 있기 때문에 NDVI 통계적 특성으로 변화를 탐지하는 무감독 분류를 추가로 수행하였다. ISODATA 알고리즘을 적용하여 유사한 패턴을 갖는 클래스로 분류하였으며 표 8-4의 무감독 분류 결과, 임계값을 사용한 결과와 비슷한 영역을 탐지할 수 있음을 확인하였다. 경험적 임계값의 적용 없이 산불 피해 범위를 추정할 수 있었으나, 산불 발생 직후와 1년 후 영상에서의 피해범위는 임계값을 적용한 결과와 유사하게 나타났다. 다만, 무감독 분류 결과 상, 산불 직후 영상과 1년 후 영상의 피해지역으로 추정되는 클래스의 구성비가 다르게 나타남을 확인할 수 있다.

<표 8-4> NDVI 기반 안동시 산불 피해범위 탐지 결과

	발생 전	산불 직후	산불 +1년 후
임계값 적용			미적용
무감독 분류			
피해 예상 범위	해당없음		
범례	<div> <div>NoData</div> <div>Class1</div> <div>Class2</div> <div>Class3</div> <div>Class4</div> <div>Class5</div> <div>Class6</div> <div>Class7</div> </div> <div>  피해예상 범위 </div>		

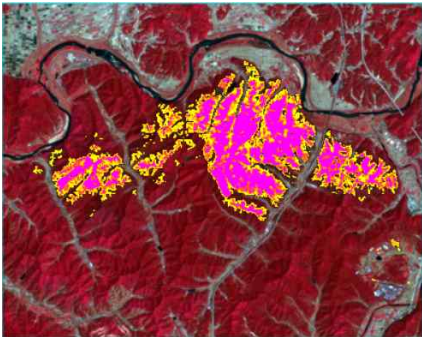
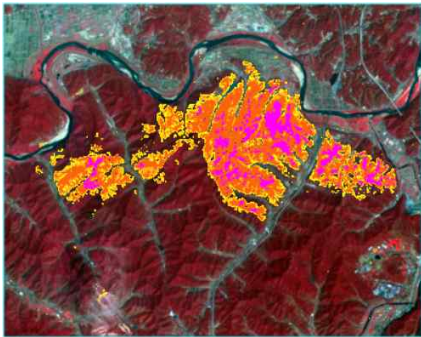
전처리가 완료된 산불 피해 전·후 영상에서 각각 NBR 지수를 계산한 다음 ΔNBR 을 통해 산불로 인한 피해 정도를 파악할 수 있다. USGS에서는 ΔNBR 범위에 따라 피해등급을 7개로 분류하고 있으며 $0.440 < \Delta NBR < 0.659$ 범위는 Moderate-high Severity, $0.660 < \Delta NBR < 1.300$ 범위는 High Severity로 정의한다. 상세한 피해등급 분류 기준은 그림 8-2에서 확인할 수 있다.

Severity Level	dNBR Range (scaled by 10^3)	dNBR Range (not scaled)
Enhanced Regrowth, high (post-fire)	-500 to -251	-0.500 to -0.251
Enhanced Regrowth, low (post-fire)	-250 to -101	-0.250 to -0.101
Unburned	-100 to +99	-0.100 to +0.99
Low Severity	+100 to +269	+0.100 to +0.269
Moderate-low Severity	+270 to +439	+0.270 to +0.439
Moderate-high Severity	+440 to +659	+0.440 to +0.659
High Severity	+660 to +1300	+0.660 to +1.300

<그림 8-2> ΔNBR 피해등급 분류

본 연구에서는 피해강도에 집중하여 살펴보고자 +0.99이하 범위에 해당하는 Enhanced Regrowth, high(post-fire), Enhanced Regrowth, low(post-fire), Unburned 등급은 Unburned로 한 개로 통합하고 총 5개의 등급으로 표현하였다. 표 9-5에 제시된 NBR 기반 산불 피해강도 탐지 결과, 산불 직후에는 피해 강도가 심하게 나타나지만 발생 1년 후에는 피해강도가 완화되고 있음을 확인 할 수 있다.


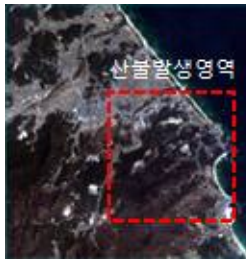



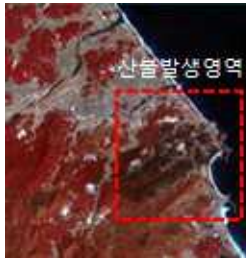


<표 8-5> NBR 기반 안동시 산불 피해강도 탐지 결과

	산불 직후	산불 +1년 후
△NBR		
범례	<div> <div>Severity Level</div> <div> <div></div> Unburned <div></div> Low Severity <div></div> Moderate-low Severity <div></div> Miderate-High Severity <div></div> High Severity </div> </div> <div> <div>dNBR Range(not scaled)</div> <div> <div>-0.500 to +0.990</div> <div>+0.100 to +0.269</div> <div>+0.270 to +0.439</div> <div>+0.440 to +0.659</div> <div>+0.660 to +1.300</div> </div> </div>	

나) 강원도 고성군 산불피해(18년 3월)

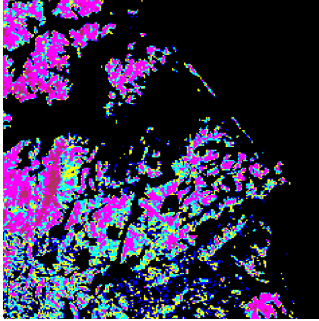
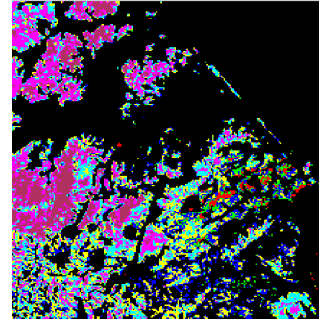


강원도 동해안 지역은 태백산맥을 넘어오는 건조한 바람과 강풍으로 인하여 산불이 한번 발생하면 짧은 시간에 큰 피해로 이어지는 지역이며 전국 산불발생 723.7건 중 강원도에서 71건이 발생할 정도로 산불이 가장 많이 발생한다(산림청, 산불발생현황, 2020). 본 연구에서는 최근 5년간 발생한 강원도 산불 중 100ha 이상 피해가 발생한 대형산불이며 Landsat 영상을 통해 피해 산불 피해 판독이 가능한 고성군 산불('18년 3월)을 대상으로 선정하였다. 표 8-6에서 제시한 RGB(Red-Green-Blue) 및 CIR(Color-infrared) 합성영상을 통해 산불피해 현황을 육안으로 확인할 수 있으며, RGB 영상보다 CIR 영상에서 시간 흐름에 따른 산림 변화가 뚜렷이 관측된다.

<표 8-6> 강원도 고성군 산불발생 지역

합성영상	발생 전(18.2.11)	산불 후(18.4.5)	산불 +1년 후	산불 +3년 후('21년)
RGB영상				
CIR영상				

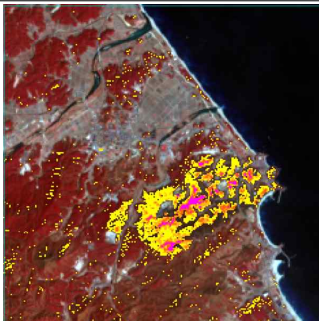
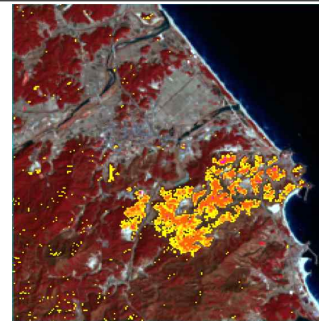
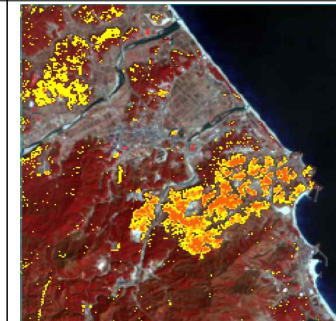
NDVI 지수를 이용한 산림지역의 산불 피해범위 탐지 결과는 표 8-7과 같다. 특정 임계값을 일반적으로 적용할 수 없기 때문에 임계값 기반의 탐지방법은 생략하였고 NDVI 산출 결과에 무감독 분류를 수행한 결과를 도출하였다. 산불 전과 산불 발생 직후의 분류 결과를 살펴보면, 산불 피해가 발생한 지역은 주로 빨간색으로 분류되었음을 확인할 수 있다. 분류된 클래스 중 산불 피해로 예상되는 영역을 가시화한 결과, 피해범위가 과소 산정된 것으로 추정된다. 산불 발생전 영상과 산불 직후, 산불 1년후, 산불 3년후 활용하여 시계열 Δ NBR을 계산하고 본 연구에서 정의한 분류 범례에 따른 결과를 표 8-8에 나타냈다. 산불 직후에는 피해 강도가 심하게 나타나지만 발생 1년 후에는 피해강도가 완화되고 있음을 확인 할 수 있었다. 토양수분에 민감한 SWIR 파장대를 이용한 Δ NBR 기법은 시간이 흐름에 따라 피해지역에 대한 피해강도가 변하는 모습이 탐지되기 때문에 산불에 대한 효과적인 모니터링이 가능할 것으로 사료된다.

<표 8-7> NDVI 기반 고성군 산불 피해범위 탐지 결과

	발생 전	산불 직후	피해예상 범위
무감독 분류			
범례	<div> <div>NoData</div> <div>Class1</div> <div>Class2</div> <div>Class3</div> <div>Class4</div> <div>Class5</div> <div>Class6</div> <div>Class7</div> </div> <div>  피해예상 범위 </div>		

산불 직후의 NDVI 무감독 분류 결과와 비교하여 살펴볼 때 Δ NBR결과에서 탐지된 피해영역이 CIR영상에서 육안으로 관측되는 영역과 유사하게 분류되는 것을 확인할 수 있다. 그러나 산불 3년 후 결과에서는 실제 피해발생지역 외에서도 산불피해로 오염지 되는 경우가 발생하였으며 산불 발생 지역을 중점 범위로 한정하여 피해 탐지가 필요할 것으로 사료된다. 산불 1년후, 21년도 최신영상에서 나타나는 피해 강도가 High Severity에서 Miderate-High Severity로 완화되고 있음을 확인할 수 있다.

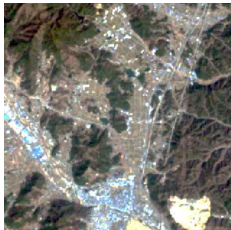
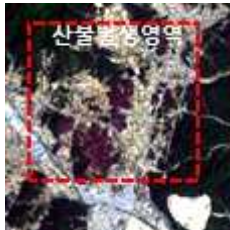
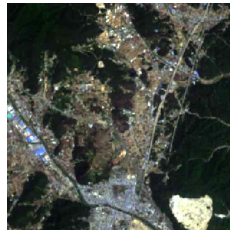
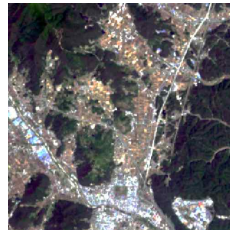
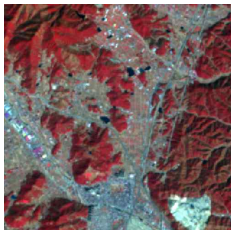

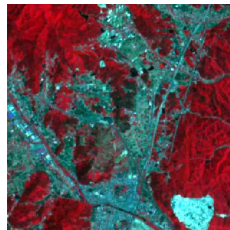
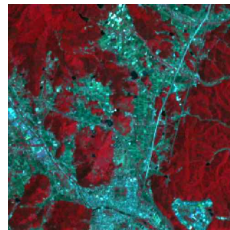
<표 8-8> NBR 기반 고성산불 피해강도 탐지 결과

	산불 직후	산불 +1년후	산불 +3년 후('21년)
Δ NBR			
범례	<div> <div>Severity Level</div> <div>dNBR Range(not scaled)</div> <div> <div>Unburned</div> <div>Low Severity</div> <div>Moderate-low Severity</div> <div>Miderate-High Severity</div> <div>High Severity</div> </div> <div> <div>-0.500 to +0.990</div> <div>+0.100 to +0.269</div> <div>+0.270 to +0.439</div> <div>+0.440 to +0.659</div> <div>+0.660 to +1.300</div> </div> </div>		

다) 울산광역시 울주군 산불피해(13년 3월)


위 두 사례는 대부분 산림피해가 주로 발생한 반면, 울산광역시 울주군에서 발생한 산불(13.3월) 경우 도심지 인근 야산에서 산불이 발생하여 주택 37동, 산림 280ha 소실, 인명피해 3명 발생하는 등 인명 및 재산 피해가 크게 발생하였다. 도시와 산림이 융합된 지역에서도 산불 피해를 잘 탐지할 수 있는지 확인하기 위하여 연구지역으로 선정하였다. 표 8-9에서 제시한 합성영상을 통해 산불피해 현황을 육안으로 확인할 수 있으며, 관심 지역 중 가장 오래전 피해가 발생하여 산불 발생 후 8년이 지난 최신영상을 살펴보면 산림이 복구된 현황이 뚜렷이 관측된다.

<표 8-9> 강원도 고성군 산불발생 지역

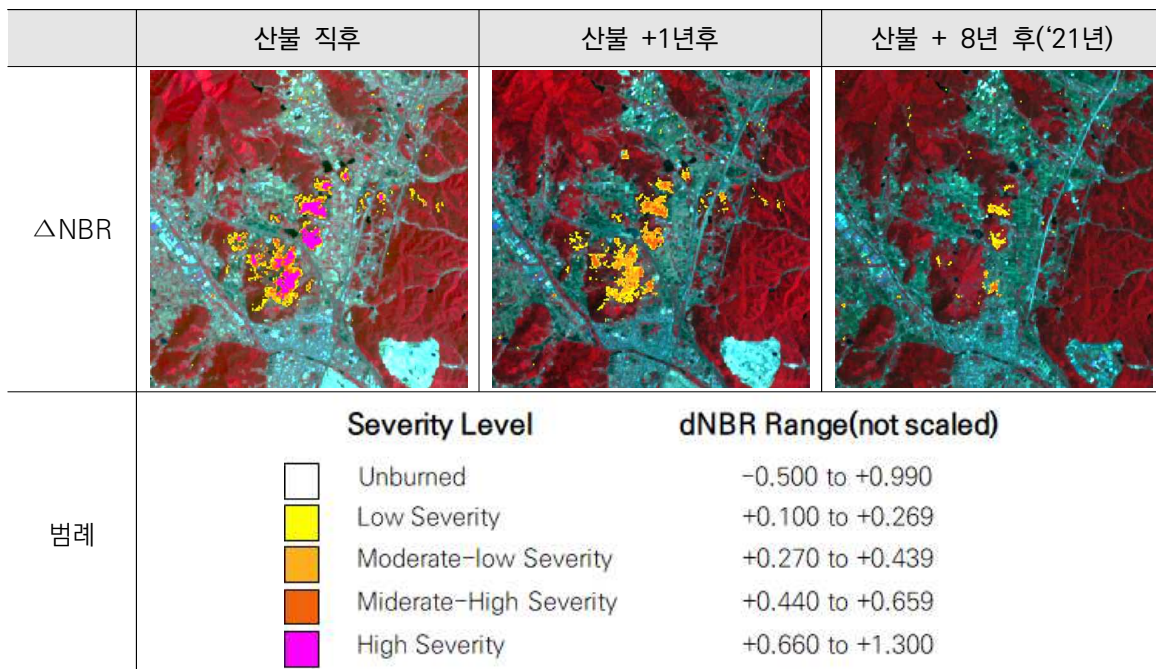
합성영상	발생 전	산불 후	산불 +1년 후	산불 + 8년 후('21년)
RGB영상				
CIR영상				

NDVI 지수를 이용한 산림지역의 산불 피해범위 탐지 결과는 표 8-10과 같다. 무감독 분류 방법을 적용하였으며, 산불 발생 직후 영상의 피해범위는 산림지역에 도심지 주변의 건물 등이 혼재되어 오탐지 된 것을 확인 할 수 있다. 표 8-11 △NBR결과에서는 시간이 지나며 피해 강도가 High Severity로 나타난 지역이 Miderate-High Severity로 완화되고 있음을 확인할 수 있었다. 최신영상('21년)을 활용하여 분석한 산불 8년 후 결과에서 High Severity 의 영역은 거의 존재하지 않으며 Low Severity의 영역만 남아있어 산림이 대부분 회복된 모습을 보이는 것으로 추정된다.

<표 8-10> NDVI 기반 울주군 산불 피해범위 탐지 결과



<표 8-11> NBR 기반 고성산불 피해강도 탐지 결과



본 연구를 통해 검증한 방법을 기반으로 피해 강도 및 범위 등 산불 발생지역의 특성을 확인가능하고, 시기별 모니터링 목적과 가용한 위성영상의 종류 등에 따라 산불에 대한 효과적인 모니터링이 가능할 것으로 사료된다.

다. 여름철 풍수해 대응을 위한 영상분석

1) 풍수해 대응을 위한 영상분석 대상 및 방법

여름철에는 태풍, 호우 등 강한 바람과 함께 하천 범람 등에 의하여 복합적인 피해가 발생한다. 특히 매년 5월15일~10월15일은 풍수해 예방 대책 기간으로 정하여 재난안전대책본부를 가동하는 등 선제적 대응을 수행하고 있음에도 불구하고 자연재해로 인해 발생하는 피해 중 풍수해 피해가 가장 큰 부분을 차지한다. 태풍과 집중호우 등으로 인해 가장 많이 발생하는 침수피해와 산사태 피해에 집중하여 여름철 풍수해 대응 방법을 모색하고자 한다.

풍수해 재난이 발생한 시기에는 구름이 동반되기 때문에 피해지역을 파악할 수 있는 광학영상 확보가 매우 어렵다. 본 연구에서는 침수피해 연구지역을 표 8-12와 같이 선정하였다. 태풍 이후에 배수가 빠르게 진행되지 않아 침수 흔적이 남아있고 재난 직후 해당지역에 구름이 없는 광학영상을 확보 할 수 있는 과거 재난 사례이다. 2020년 하이선으로 인한 북한 원산지역 피해, 2019년 태풍 미탁으로 인한 경상남도 해남군 피해, 2018년 태풍 콩레이에 의한 경상남도 거제시 피해, 2018년 집중호우로 인한 전라남도 보성군 피해를 분석한다. 또한 본 연구에서 도출한 방법을 기반으로 올해 오마이스 태풍으로 인해 발생한 경상남도 부산시의 침수피해에 적용하고 분석 결과를 공유하고자 한다. 풍수해 기간에는 침수 등으로 인한 2차 피해로 산사태가 발생할 위험이 높다. 집중호우가 원인이 된 전라남도 광양시의 산사태 피해를 탐지 결과를 소개한다.

<표 8-12> 과거 침수피해 탐지를 위한 수집 영상 정보

연구지역	발생일	위성종류	촬영일	비고
태풍 하이선 피해 (북한 원산)	2020.9.1~9.8	광학	(피해 전) 2019.08.31	Sentinel-2
			(피해 후) 2020.09.09	
		SAR	(피해 전) 2020.08.25	Sentinel-1
			(피해 후) 2020.09.06	
태풍 미탁 피해 (경상남도 해남군)	2019.10.1~10.4	광학	(피해 전) 2019.09.17	Landsat-8
			(피해 후) 2019.10.03	
		SAR	(피해 전) 2019.09.24	Sentinel-1
			(피해 후) 2019.10.06	
태풍 콩레이 피해 (경상남도 부산시)	2018.10.4~10.7	광학	(피해 전) 2017.09.12	Sentinel-2
			(피해 후) 2018.10.07	
		SAR	(피해 전) 2018.09.24	Sentinel-1
			(피해 후) 2018.10.03	
집중호우 피해 (전라남도 보성군)	2018.6.26~7.4	광학	(피해 전) 2017.07.27	Sentinel-2
			(피해 후) 2018.07.07	
		SAR	(피해 전) 2018.06.25	Sentinel-1
			(피해 후) 2018.07.07	

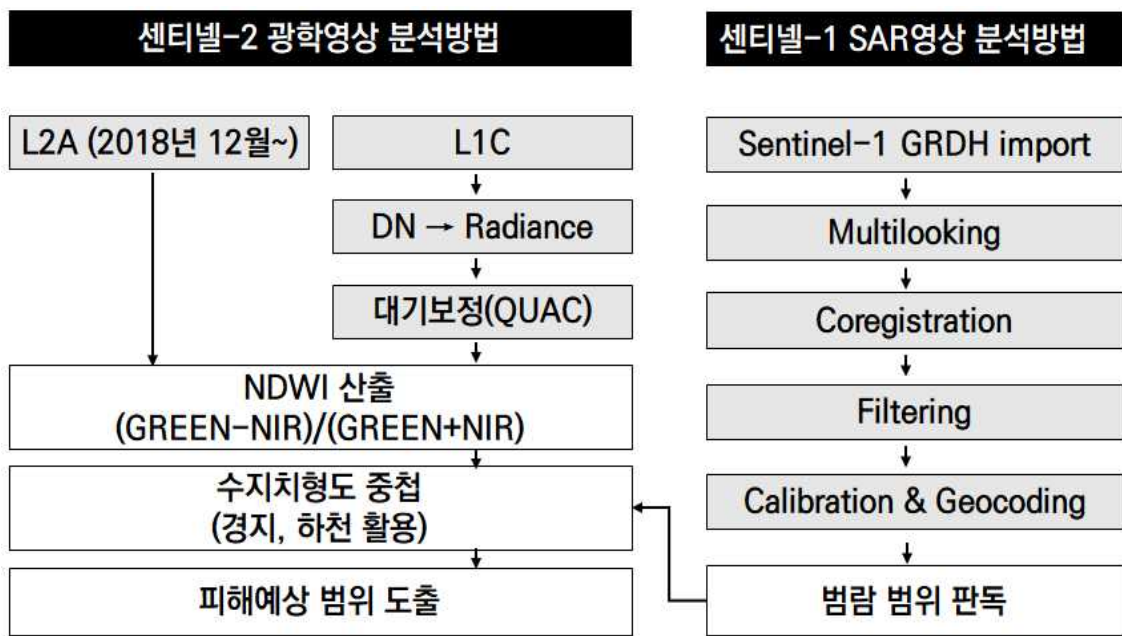
무료 영상으로 배포되는 대표적인 광학영상 Sentinel, Landsat을 활용하여 수집하였으며 침수 피해 지역을 파악하기 위해서는 홍수 발생 전후의 시계열 영상이 필요하다. 위성영상 제원은 표 8-13과 같다.

<표 8-13> 위성 영상 제원

센서종류	센서특성	영상해상도	관측폭	재방문주기	발사일
Landsat-8(US)	광학	30m	185km	16일	2013.2.11.(L8)
Sentinel-2(EU)	광학	10m	290km	5일 (2기 운영)	2015.6.23.(2A) 2017.3.7.(2B)
Sentinel-1(EU)	SAR	5m×20m	250km	6일 (2기 운영)	2014.4.3.(1A) 2017.4.25.(1B)


영상 수집 후, Landsat-8은 영상 전처리(방사보정, QUAC 대기보정) 과정이 수행된다. Sentinel-2는 2018년 12월 이후로 전처리 없이 즉시 영상 분석이 가능한 L2A 산출물을 제공하고 있다. 이전 영상은 L1C 형태로 제공되며, Landsat 영상의 경우와 마찬가지로 동일하게 전처리 과정이 수행되어야 한다(그림 8-3). 광학영상은 지표면의 수분 함유량을 파악하는데 유용한 정규수분지수(NDWI, Normalized Difference Water Index)를 적용하여 침수 피해지역을 탐지할 수 있다. NDWI는 식생이나 지표면에 포함된 수분 함유량을 나타내는 지수로 녹색 영역 분광밴드와 근적외 밴드를 활용하여 하천, 호수, 습지 등 수분을 다량으로 함유한 지형지물을 탐지한다.

<그림 8-3> 여름철 침수 피해 탐지 흐름도




피해지역 데이터는 영상기반의 래스터 자료로 작성되어 있어, GIS 등에 효과적으로 분석하기 위하여 벡터 형태의 데이터로 변환을 수행한다. 벡터 데이터로 변환된 자료는 분석 결과의 정확도를 높이기 위해 연속수치지도의 수계 데이터(하천, 저수지, 바다 등)에서 피해지역으로 분류된 지역은 마스킹 한다. 피해지역의 수계 현황을 고려하지 않고 피해면적을 산출함으로써 인하여 실제 피해면적에 차이가 발생할 수 있다는 점에서 국토지리정보원에서 제작한 연속수치지도를 활용하여 피해지역 및 피해 면적의 정확도를 향상시킬 수 있다(국토지리정보원, 2020).

광학영상은 피해 탐지에 적합한 영상 확보에 한계가 많기 때문에, 구름의 영향을 거의 받지 않고 영상 취득이 가능한 SAR 영상의 활용성 또한 검토하였다. SAR 영상은 인공위성에서 마이크로파를 발사하고 지면에 반사되어 나오는 신호의 세기를 이용하여 지형·지물 형상을 파악할 수 있다. 도심지, 산림 등 지형이 불규칙하고 지물이 많은 지역에서는 SAR 센서에 반사되어 오는 신호가 많아 밝게 나타나지만 물, 얼음, 도로 등과 같이 표면이 평평한 지형에서는 전파가 다른 곳으로 산란하여 반사되어 흩어져 인공위성 센서에 돌아오는 신호가 매우 적어 어둡게 나타나는 특성을 보인다(국토지리정보원, 2020). SAR영상을 활용하여 산불, 풍수해, 환경오염, 지진 등에 대응하는 다양한 연구가 이루어지고 있으며, 풍수해 대응과 관련하여서는 침수 피해지역 탐지 및 완화방안 도출(이명진 외, 2009), 지형자료를 융합한 침수지역 판별(김수현 외 2019) 등 침수피해 지도와 연계한 연구가 진행되고 있다. SAR 영상은 신호처리 자료로서 후방산란계수의 값으로 이미지가 구성되며 광학영상과 같이 즉각적인 영상 판독이 어렵기 때문에 전처리가 수행되어야 한다. ENVI 5.5.3 및 SARscape 5.0 이용하여 처리하였으며, 그림 8-3 절차와 같이 진행하였다. SARscape Basic Module을 활용하여 Sentinel-1 GRDH 원시 데이터에서 SARscape Raster 포맷으로 변환을 수행한다. 변환된 입력자료를 이용하여 Range 및 Azimuth에 대한 공간 필터링 과정 및 Coregistration 과정, 노이즈를 완화시켜주는 Filtering 과정을 수행한다. 산란에 의해 스펙클 노이즈가 무작위로 발생하게 되는데, Lee sigma, Frost 등 다양한 방법이 존재하나 본 연구에서는 De Grandi Spatio-Temporal 필터를 적용하였다. GRD(Ground Range Detected) 영상은 그림 8-4에서와 같이 영상 진행 방향으로 촬영된 영상이 제공되므로 지도좌표계 변환과 지형보정을 위해 DEM을 활용한다. 공개용 SRTM(Shuttle Radar Topography Mission) DEM을 활용하여 Calibration & Geocoding 과정을 수행하였다(SARscape Intensity Processing Tutorial, 에스이랩). 이상의 처리 과정을 거치게 되면 그림 8-5와 같이 SAR 영상 활용을 위한 데이터 처리가 완료된다.



<그림 8-4> GRDH 원시 영상



<그림 8-5> 전처리 완료 영상



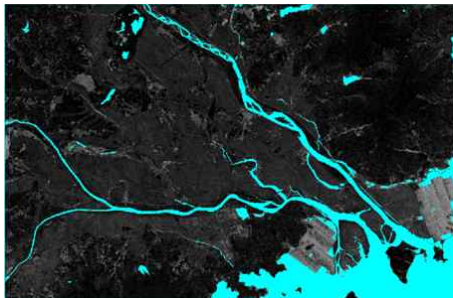
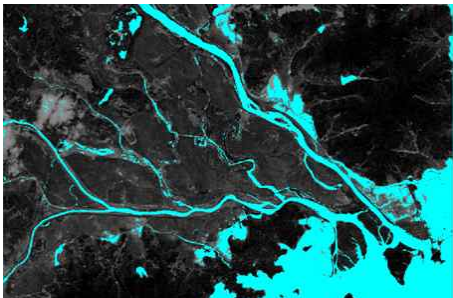
2) 침수피해 영상분석 결과

가) 과거 침수피해 영상분석

먼저 2020년 태풍 하이선 피해(북한 원산) 사례이다. 2020년, 남한뿐만 아니라 북한지역도 9호 태풍 마이삭과 10호 태풍 하이선에 의한 피해가 크게 발생하여 원산·신포 일대가 물에 잠기는 등 초토화되었다고 조선중앙텔레비전에 보도되었다. 해당 지역의 영상을 검색한 결과 태풍 이후 재난 대상 지역에 구름이 없는 광학영상을 확보할 수 있었다. 식생이나 지표면에 포함된 수분함유량을 나타내는 정규수분지수(NDWI)는 식생 및 나지지역과 수계지역을 효과적으로 구분할 수 있다. 식생 및 나지지역은 낮은 값을 갖기 때문에 어둡게 표현되며, 수계영역은 높은 NDWI 값을 가지며 영상에서 밝게 나타난다. NDWI 0.3~0.4의 임계값을 기준으로 미만의 값은 비수계 지역, 이상은 수계 지역으로 정의하고 있다(McFeeters, S. K., 2013, Acharya, T. D. et al., 2018). 본 연구에서는 영상 내 경험적 임계값을 산출하여 표 8-14와 같이 $NDWI > 0$ 이상의 범위를 수계로 분류하였다.

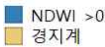


해당지역은 태풍 발생 전과 발생 후 광학영상 비교를 통해 육안으로도 피해 지역이 파악되며, 수계 일부분이 태풍으로 인해 흙탕물로 변한 것을 확인할 수 있다. NDWI 추출 결과는 파란색으로 가시화하였다. RGB 영상으로 육안으로 확인 되는 부분 외에도 바다와 인접한 해안가 부분에서 일부 침수 피해가 발생했음을 확인할 수 있었다. 그러나 NDWI에 단순 임계값을 적용하여 수계 지역을 검출할 경우 다수의 비수계 지역도 함께 수계 지역으로 검출되는 문제점을 있기 때문에 비수계 지역이 수계지역으로 검출되는 것을 방지할 추가적인 정보가 필요하다.

<표 8-14> 광학영상 NDWI 기반 피해 범위 탐지

센티넬2	태풍 발생 전	태풍 발생 후
RGB영상		
NDWI > 0		

본 연구에서 2016년 북한지역의 1/5,000 연속수치지도의 저수지, 하천, 농경지 등의 레이어를 이용하여 저수지와 하천에 해당하는 레이어를 수계로 분류 및 마스킹 파일을 적용하여 피해지역 구분에 활용하였다. 또한 NDWI 결과와 연속수치지도의 농경지 레이어 중첩을 통해 표 8-15와 같이 침수 피해로 예상되는 대부분의 지역이 농경지임을 확인 할 수 있었다.

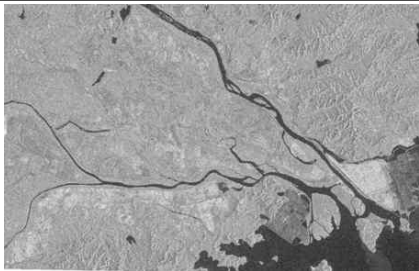
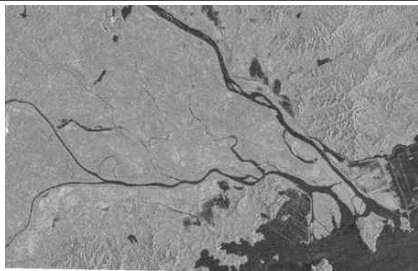

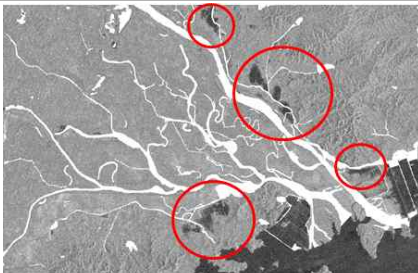
<표 8-15> NDWI 결과와 수치지형도 중첩

범례	태풍 발생 전	태풍 발생 후
		


해당 지역에 대해 SAR 영상 전처리가 완료된 결과는 표 9-16과 같다. 광학 영상에서는 피해 후 영상의 왼쪽 부분은 구름에 가려 지형 정보를 확인 할 수 없었으나 SAR 영상에서는 구름의 영향 없이 영상이 촬영되어 피해 전역에 대한 피해 현황 파악이 가능하다. 또한 광학 영상과 비교 하였을 때 NDWI 지수 산출 없이도 수계 및 침수피해가 예상되는 부분이 물이 표면 반사도가 낮아 어둡게

표현되는 것을 확인 할 수 있다. 침수로 인한 피해만을 확인하기 위하여 수치지형도에서 추출한 수계 레이어를 마스킹한 결과, 바다 영역과 피해가 예상되는 부분의 영역만 영상에서 어둡게 표현되었다. 바다와 인접한 논 지역 또한 침수 피해와 같이 어둡게 나타났다. SAR영상 특성상 활주로, 운동장, 갯벌, 논, 밭 등 표면의 상대적 거칠기가 수면과 매우 유사하여 물과 거의 같은 레이더반사 값을 나타낸다. 물이 찬 논의 경우 거의 물 표면과 같은 레이더반사 값을 보이게 되며, 이 시기의 레이더 영상에서 수면과 논을 제대로 구별하기는 매우 어렵다(이명진, 2004).

<표 8-16> SAR 기반 피해 범위 탐지

센티넬1	태풍 발생 전	태풍 발생 후
Amplitude 영상		
수치지형도 수계지역 마스킹		





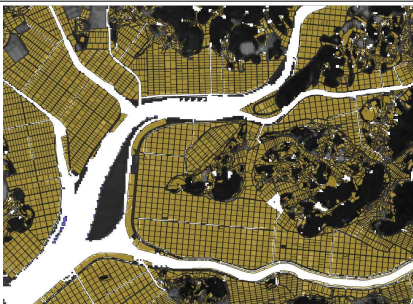
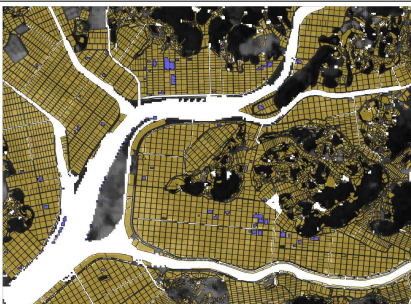


SAR영상과 광학영상의 NDWI결과와 수계 레이어를 중첩한 결과, 그림9-6과 같이 SAR영상에서 어둡게 표현되는 부분은 광학영상의 NDWI에서 수계로 추출되는 영역과 유사하게 도출됨을 확인 할 수 있었다.



<그림 8-6> 태풍 하이선 침수피해 분석 결과

다음은 2019년 태풍 미탁 피해(경상남도 해남군) 사례이다. 20년 태풍 하이선 사례에서 제시한 방법을 동일하게 적용하였다. 피해 당시 해남군은 재난특별지역으로 선정될 정도로 피해가 크게 발생하였으나 표 8-17과 같이 취득한 태풍 발생 후 광학영상에서는 범람 예상 영역으로 추정할 수 있는 $NDWI > 0$ 이상의 값을 갖는 영역(보라색 표기)이 논경지(노란색 표기) 중 일부에서 나타남을 확인할 수 있었다. 매우 작은 영역이라 SAR영상에서는 물로 확인되는 특성이 확인되지 않았다.

<표 8-17> 광학영상 NDWI 기반 피해 범위 탐지

센티넬2	태풍 발생 전	태풍 발생 후
광학 영상		
$NDWI > 0$ (보라색 영역)		
수치지형 도(논경지) 와 $NDWI > 0$ 중첩		
SAR 영상		

2018년 태풍 콩레이 피해(경상남도 부산시)와 2018년 집중호우 피해(전라남도 보성군) 사례의 영상기반 피해 범위 탐지 결과, 표 8-18과 표 9-19와 같이 피해 범위를 탐지 할 수 없었다. NDWI 결과와 SAR 영상에서 저수지 주변의 물이 찬 모습 정도만 확인 할 수 있었다. 북한 사례와 달리 우리나라 도시지역은 풍수해 발생 후 빠른 배수로 인하여 침수 현황을 확인에 어려움이 있었다.

<표 8-18> 2018 콩레이 피해 : 영상 기반 피해 범위 탐지

센티넬2	태풍 발생 전	태풍 발생 후
광학 영상		
NDWI>0		
SAR영상		

<표 8-19> 2018년 집중호우 피해 : 영상 기반 피해 범위 탐지

센티넬2	태풍 발생 전	태풍 발생 후
광학 영상		
NDWI>0		
SAR영상		

나) 2021년 하절기 긴급 공간정보 대응(태풍 오마이스 피해)

올해 8월에는 12호 태풍 오마이스가 발생하였다. 우리나라에 상륙한 첫 태풍으로, 많은 비를 동반하여 남부지역에 곳곳에서 도로 및 주택 등이 침수되었다. 남부지역에 동시다발적으로 발생한 주요 침수 사례 중, 재난 발생 시간, 영상 확보 가능성, 규모 등을 고려하여 부산시 임기천 범람 재해를 선정하였으며 구름의 영향으로 광학 영상 확보가 어려움에 따라 SAR 위성영상 촬영을 요청하고 및 재난 발생지의 기상상황을 고려한 드론 촬영 가능 여부를 확인하였다. SAR, 드론의 신규 촬영 영상을 재난 발생 1일 이내 확보하고 국토지리정보원에서 생산한 기 구축 자료 항공사진, 수치지도를 중첩하여 피해현장 및 상황 등을 데이터로 가공하였다.

우리나라 침수 피해의 주요 원인은 하천수위 상승에 따른 내수범람에 의한 것이 대부분으로, 하천 주변 저지대에서 주로 발생한다(국토연구원, 2008). 짧은 시간 내 하천 주변에 물이 범람하여 발생하기 때문에 배수가 완료되면 흔적을 확인 하기가 매우 어려우며 재난 발생 즉시 피해현황을 파악하고 신속한 복구 활동이 이루어진다. 재난상황 발생 후 재난현장 정보를 파악하기 위해서는 위성, 항공, 드론 등을 활용할 수 있으며, 부산시 임기천 범람 사례에서는 SAR 영상 및 드론 영상을 취득하여 분석하였다. SAR 영상에서 물은 반사도가 매우 낮기 때문에 어두운 색으로 보이는 특성을 분석하여 범람 수역을 판독할 수 있으며, 풍수해에 SAR 위성을 활용한 침수 피해지역 탐지 및 완화 방안 도출(이명진 외, 2009), 지형자료를 융합한 침수지역 판별(김수현 외, 2019) 등의 연구가 진행되고 있다. 그림 8-7과 같이 이번 사례는 하천 반경 20m 좁은 범위에서 피해가 발생하였으며, 침수 범위가 좁았던 점과 빠르게 배수가 완료됨에 따라 15시간 뒤 촬영된 SAR 영상에서 침수지역이 뚜렷하게 식별되지 않는 한계가 있었다. 피해현황을 직관적으로 파악하기 위하여 드론 영상을 활용하였으며, 국토지리정보원에서 보유하고 있는 수치지도(1/5,000)의 건물 및 하천 레이어를 중첩하였다. 드론 촬영의 경우 긴급히 촬영되어 기 구축된 고정밀의 공간정보와 정확하게 중첩되진 않았으나 육안으로 피해 지역 및 시설물을 파악하기에 충분하였다.



<그림 8-7> (위) 영상 및 공간정보 중첩 비교 (아래) 피해 현장 사진


3) 산사태피해 영상분석 결과

7월 6일, 전남 광양시 진상면 일원에서 집중호우에 따른 산사태역의 드론 피해가 발생(가옥 등 4채 매몰, 1명 사망)하였고, 긴급 공간정보 운영방안에 따라 해당 지역에 대한 긴급 공간정보를 구축하였다. 장마전선 등 광범위한 영역에 구름의 영향으로 위성영상 확보는 어려웠으나 신속히 해당 지 촬영을 수행하여 피해 상황을 파악할 수 있었으며, 기 구축한 과거 항공영상을 확보하여 시계열 영상정보를 구축하였다.



<그림 8-8> 산사태 지역 시계열 영상

산사태 상황 인지와 동시에 긴급공간정보 구축 사업단의 현장 대응 활동 가동을 통해 익일 피해 지역의 드론 영상 및 수치지형모델(DEM, DSM)을 확보 할 수 있었으며, 취득한 드론영상과 함께 국토지리정보원에서 보유하고 있는 항공영상(25cm), 수치지도(1/5,000), 인구 및 건축물 통계정보(100m 격자)를 신속하게 패키지로 가공하여 긴급 공간정보를 구축하고 행정안전부, 전라남도, 광양시, 산림청 등 8개 관계기관을 대상으로 긴급 공간정보 서비스를 제공하였다. 아래 그림은 시계열 항공 및 드론영상과 수치지도에서 제공하는 건물 레이어, 산림청 산림정보시스템에서 제공하는 산사태 위험지도를 중첩하여 비교한 결과이다.



<그림 8-9> 드론영상 기반 DSM 제작 및 건물중첩

이번 산사태 발생 지역은 산사태 위험 1등급 지역 부근으로 확인되며 사면붕괴 지역 주변에서 발생한 산림 유실 및 건물 피해를 육안으로 파악할 수 있었다. 또한 드론영상을 기반으로 구축한 DSM의 음영기복도를 통해 산사태 발생지역의 지형변화를 명확하게 확인 할 수 있었다.

라. 겨울철 대설 대응을 위한 영상분석

1) 대설 대응을 위한 영상분석 대상 및 방법

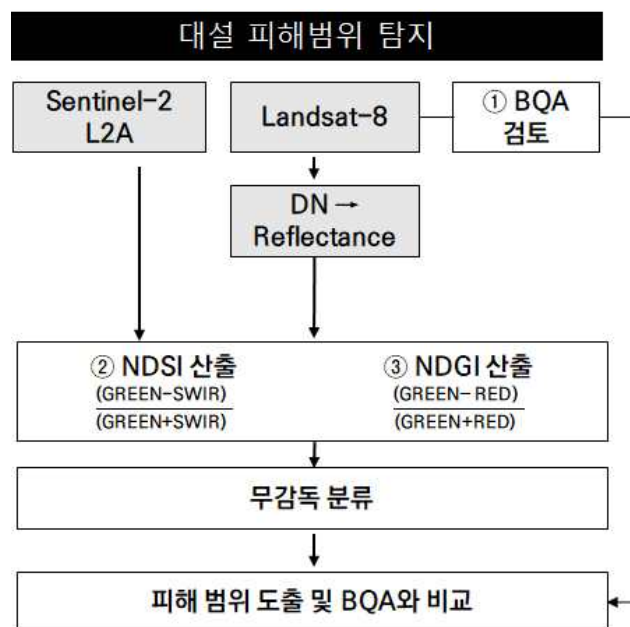
12월부터 2월은 본격적인 겨울로 대설과 한파로 인한 피해가 증가하는 시기이며 통계적으로 살펴보면 최근 10년간('09~'18년) 겨울철(12월~2월)에 총 29회의 대설이 발생하였다(행안부, 2019). 과거 사례 중 비닐하우스 붕괴, 도로 등에서 큰 피해가 발생한 2018년 1월 서해안 폭설 사례와 올해 발생한 3월 강원도 폭설 지역을 대상으로 대설 피해 탐지 가능성을 연구하고자 한다.

<표 8-20> 대설 피해 탐지를 위한 수집 영상 정보

연구지역	발생일	위성종류	촬영일
서해안 폭설	2018.01.10.~11	Landsat-8	2018.01.10
강원도 폭설	2021.03.01	Sentinel-2	2021.03.03

2018년도는 가용한 위성영상으로 Landsat-8영상을 확보하였으며 특히 Landsat-8에서 제공하는 BQA(Band Quality Assessment) 밴드는 영상 내 구름, 눈에 해당하는 픽셀정보를 제공하기 때문에 이를 활용하여 눈덮인 지역을 대략적으로 파악 할 수 있다. 2021년도 강원도 폭설은 Sentinel-2 영상을 수집하였으며 Sentinel-2 영상의 L2A 산출물은 지형보정과 대기보정 전처리가 완료된 영상이므로 Reflectance 전처리는 생략하였다.

<그림 8-10> 겨울철 적설지역 탐지 흐름도



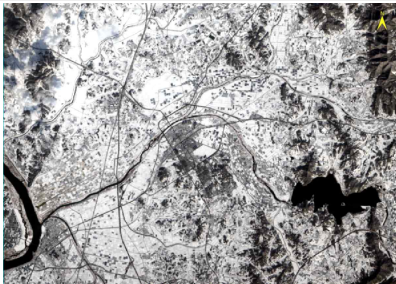

전처리 완료 후 그림 8-10 흐름도와 같이 눈 탐지에 유용한 지수인 정규강설지수(NDSI, Normalized Difference Snow Index)와 빙하 모니터링이 가능한 정규빙하지수(NDGI, Normalized Difference Glacier Index)를 적용하고 무감독 분류를 수행하였다. 피해범위 결과를 비교하여 적설지역 탐지에 가장 적합한 방법을 도출하고자 한다.

2) 적설지역 모니터링 결과

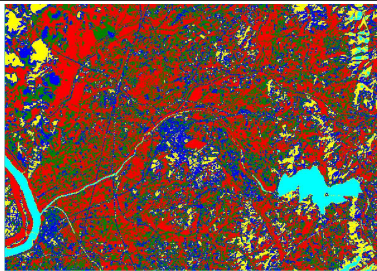
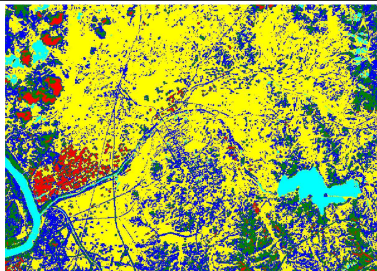

가) 2018년 적설지역 영상분석

대설이 발생한 지역은 표 8-21과 같다. 눈과 구름은 가시광(RED) 및 근적외선(NIR)에서 유사한 반사도를 갖으나 단파적외(SWIR) 파장대에서는 눈의 반사도가 매우 낮게 나타나는 특성이 있다. 이러한 특성을 이용하여 영상 합성(SWIR-NIR-RED)을 수행하면 눈과 구름을 구별 할 수 있다. 합성영상에서 구름과 눈이 쌓이지 않은 논경지 영역은 흰색으로 보이며, 눈이 쌓인 지역은 하늘색으로 표현된다.

<표 8-21> 광학영상(Landsat-8) 기반 적설지역 탐지

Landsat	RGB 영상	합성영상(SWIR-NIR-RED)
서해안 폭설 18.1.10		

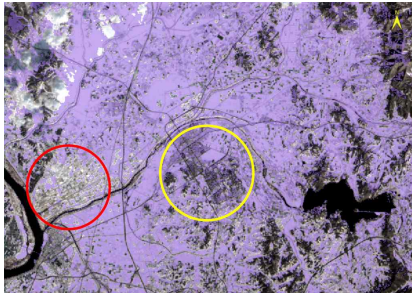
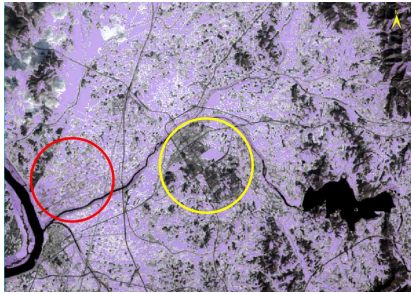
<표 8-22> 지수산출 및 무감독 분류 방법을 적용한 적설 지역 탐지

구분	정규빙하지수(NDGI)	정규강설지수(NDSI)
무감독 분류 결과		
범례		

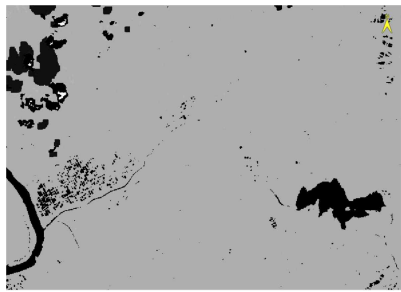

전처리 완료 영상에 정규빙하지수와 정규강설지수를 적용하고, 무감독 분류를 적용하여 5개의 클래스로 구분하여 표 8-22에 제시하였다. 앞서 설명한 산불 분석 방법론 정립할 때의 경험에 비추어 볼 때, 정규화 지수에서 경험적 임계값을 추출하는 것은 계절적 영향, 지역 특성 등에 의해 변할 수 있기 때문에 각각 정규화 지수 결과에 무감독 분류 방법을 적용하였다. 분류 결과, 정규빙하지수에서는 빨간색으로 표현한 Class1 영역이 적설지역으로 확인되며, 정규강설지수에서는 노란색으로 표현한 Class 4가 적설지역인 것으로 확인된다. 표 8-23은 육안으로 적설지역으로 구분한 클래스만을 추출하여 보라색으로 표출한 결과이며, 표 8-24에는 Landsat 영상에서 제공하는 QA 밴드에서 snow에 해당하는 값은 회색으로, 그 외 값은 검정색으로 가시화하였다. QA밴드에서 적설 영역으로 제시되는 영역을 참값으로 두고 산출한 지수 결과와 비교해 보았을 때 NDGI, NDSI 모두 QA밴드 값과 유사하게 구름과 수계 영역은 잘 구분 되었으나 논경지와 도심지 영역에서 탐지결과와 차이가 확인된다.

합성영상에서 표시한 빨간색 동그라미 영역을 살펴보면 논경지에서는 눈이 쌓이지 않은 것으로 파악되는데 NDSI는 이 영역까지 적설지역으로 판단한 반면 NDGI는 비적설지역으로 구분하였다. 또한 합성영의 노란색 동그라미 영역의 경우 도심지가 눈이 뒤덮인 것으로 확인되는데, NDSI는 비적설 지역으로 구분하고 있다.

<표 8-23> 무감독 분류 결과, 적설지역 클래스

구분	정규빙하지수(NDGI) : 클래스1	정규강설지수(NDSI) : 클래스 4
적설지역 표출		


<표 8-24> Landsat-8 QA밴드 및 합성영상

구분	QA 밴드 : 적설영역(회색)	합성영상(SWIR-NIR-RED)
적설지역 표출		

나) 2021년 적설지역 영상분석

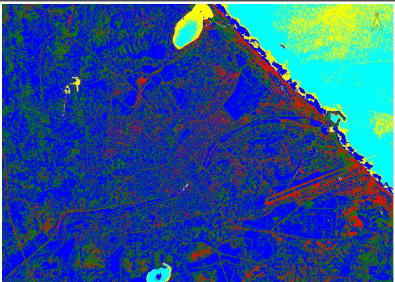
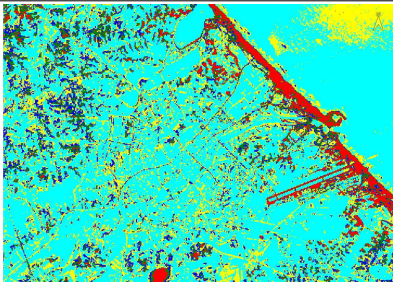



21년 3월, 강원도 지역에 대설특보가 발생하였다. 그림 8-11에서 확인 할 수 있듯이 강릉시 대부분이 눈으로 뒤덮여있으며 Sentinel 광학영상으로 RGB 영상 확인결과, 영상의 모든 영역이 하얗게 확인된다.

<표 8-25> 광학영상(Sentinel-2) 기반 적설지역 탐지

Sentinel	RGB 영상
강원도 폭설 21.3.3	

Sentinel-2 영상을 이용하여 NDGI와 NDSI 지수를 산출하고 무감독분류를 적용한 결과는 표 8-26과 같다. 정규빙하지수에서는 육안상 파란색으로 표현한 Class 3 영역이 적설지역으로 확인되며, 정규강설지수에서는 옥색으로 표현한 Class 5가 적설지역인 것으로 확인되며, 육안으로 적설지역으로 구분한 클래스만을 추출하여 보라색으로 표출하였다.

<표 8-26> 2021년 적설 지역 탐지

구분	정규빙하지수(NDGI)	정규강설지수(NDSI)
무감독 분류 결과		
범례		
적설지역 추출		

NDGI와 NDSI 분류 결과 내륙지역은 비슷하게 대부분 적설지역으로 파악되나 NDSI 결과는 인근 바다영역이 적설지역으로 오탐지 됨을 확인 할 수 있다.

지수 및 무감독 분류를 적용하여 적설지역 탐지 분석결과, 2018년, 2021년 대설 사례 모두 구름과 적설은 잘 구분되나, 바다지역이 인접한 경우 정규강설지수(NDSI)는 바다 수계영역은 오탐지며, 논경지 및 도심지역에서 오탐지가 나타났다. 정규빙하지수(NDGI)를 이용하였을 때 적설 영역이 좀 더 정확히 탐지됨을 육안으로 확인 할 수 있었다. 정규빙하지수는 녹색밴드와 적색밴드를 이용하고, 국토위성은 해당 밴드를 갖고 있기 때문에 적설지역 파악에 활용할 수 있을 것으로 기대한다.

3. 결론 및 기대효과

본 연구에서는 위성영상 분석 기술을 과거 및 올해 발생한 재난에 적용하여 긴급 공간정보 제공에 활용하였다. 산불 재난의 경우 본 연구를 통해 검증한 방법을 기반으로 피해 강도 및 범위 등 산불 발생지역의 특성, 시기별 모니터링 목적, 가용한 위성영상의 종류 등에 따라 산불에 대한 효과적인 모니터링이 가능할 것으로 사료된다. 풍수해 재난의 경우 구름 등으로 인하여 광학영상으로 재난 즉시 피해 현황 파악이 어려운 경우도 있었다. 재난 발생 직후 최대한 빨리 가용한 신규 영상 취득을 수행하였고, 침수 및 산사태 피해를 확인하기 위하여 광학 위성과 드론 및 SAR 영상 융합 방법을 적용하여 재난 피해를 탐지할 수 있는 방안을 도출하였다. 향후 본 연구에서 선정한 재난유형에 대해서는 재난유형별 분석 가이드를 제공하여 이를 통해 누구나 쉽게 위성영상을 분석하고 재난에 활용할 수 있는 환경을 마련할 예정이다. 이를 통해 재난 유형별로 재난 피해 범위를 과학적으로 탐지할 수 있는 기반이 마련될 것이다.

참고문헌

- 긴급 공간정보 제공체계 기획연구, 2020, 국토지리정보원
- 김수현, 이상구, 김태웅, & 김동균. (2019). 인공위성영상과 지형자료를 동시에 활용한 침수지역 판별.
- 김지현, 손소영, & 김연주, 2019. 2019년 강원도 산불로 인한 증발산 변화 원격탐사기반 추산. *Journal of Korea Water Resources Association*, 52(11): 941-946.
- 레이더 위성영상을 이용한 홍수피해 분석에 관한 연구, 학위논문, 2004
- 산림청 (2021), 2020년 산불통계연보
- 원명수, 장근창, 윤석희, & 이훈택, 2019. 강원도 대형산불지역의 열해 피해로 인한 피해강도 변화 탐색. *대한원격탐사학회지*, 35(6_2): 1083-1093.
- 원명수, 구교상, & 이명보, 2007. Landsat 영상으로부터 정규탄화지수 추출과 산불피해지역 및 피해강도의 정량적 분석. *한국지리정보학회지*, 10(3): 80-92.
- 통계청, 홈페이지 산불발생현황(2020)
- 행정안전부 (2019). 재난안전 상황분석 결과 및 중점관리 대상 재난안전사고
- 이명진, 명수정, 전성우, & 원중선. (2009). 레이더 위성영상을 활용한 침수피해 지역 파악 및 완화방안 연구. *환경정책연구*, 8(2), 1-23.
- Acharya, T. D., Subedi, A., & Lee, D. H. (2018). Evaluation of water indices for surface water extraction in a Landsat 8 scene of Nepal. *Sensors*, 18(8), 2580
- McFeeters, S. K. (2013). Using the normalized difference water index (NDWI) within a geographic information system to detect swimming pools for mosquito abatement: a practical approach. *Remote Sensing*, 5(7), 3544-3561.
- Taufik, A., Ahmad, S. S. S., and Ahmad, A. 2016. Classification of Landsat 8 satellite data using NDVI thresholds. *Journal of Telecommunication, Electronic and Computer Engineering*, 8(4): 37-40.
- 심우배. (2008). 우리나라 도시침수피해 특성과 정책과제. *국토정책 Brief*, (189), 1-8.
- 이명진, 외. (2009). 레이더 위성영상을 활용한 침수피해 지역 파악 및 완화방안 연구. *환경정책*

연구, 8(2), 1-23.,

김수현, 이상구, 김태웅, & 김동균. (2019). 인공위성영상과 지형자료를 동시에 활용한 침수지역
판별. 한국방재학회논문집, 19(7), 471-483

<https://www.un-spider.org/fr/node/12318>

제9장

빅데이터 기반 대용량 위성영상 처리 및 서비스 제공 기초 기술 조사

-
1. 연구의 배경 및 목적
 2. 주요 내용
 3. 결론 및 기대효과

1. 연구의 배경 및 목적

국토위성영상은 한반도, 동아시아, 전지구 단위의 고부가가치 영상(0.5m)을 취득할 수 있는 핵심인프라로 국토위성발사(21.3) 성공에 따라 10월 18일부터 정상운영중이다. 국토위성센터는 항우연이 제공하는 기본영상(L1R)을 수집하고 이를 가공하여 위성정사영상을 활용 산출물로 생산한다. 국토위성의 고해상도 영상은 한반도 촬영시(80초) 48장(12km × 12km)이 생성되며 매일 약 60GB(1장 * 약 1.3GB)의 표준영상이 취득된다. 표준영상 뿐만 아니라 위성정사영상, 활용산출물의 용량까지 고려하면 매일 대용량의 위성자료가 생산될 것으로 예상된다. 최근 데이터의 종류와 양이 증가하고, 각각의 데이터 또한 고용량화 되면서 대용량 자료처리에 대한 관심이 높아지고 있다. 다차원 배열 데이터베이스(SciDB)는 클러스터 기반 데이터 관리 및 분석을 통해 대용량 과학데이터 처리에 적합하며 대규모 데이터 분석을 위해 별도의 병렬 프로그래밍이 불필요하기 때문에 위성 빅데이터 처리 방법으로 주목받고 있다. 본 연구에서는 대용량 위성데이터를 효율적으로 수집 및 저장하고 신속히 처리하여 국토영상을 원하는 사용자에게 신속히 제공할 수 있도록 다차원 배열 데이터베이스(SciDB) 기술 기반의 대용량 위성영상 저장 및 처리 기술에 대해 검토하였다. 또한 SciDB를 기반으로 웹에서 대용량의 위성정보를 효율적으로 검색하고 표출할 수 있는 방법 등 서비스 제공 기초 기술을 조사하였다. 현재 기술현황 리뷰를 위하여 주요 참고문서로 한국과학기술정보연구원에서 수행한 과학기술 빅데이터 공유·융합체제 구축(2013년~2017년) 사업 보고서를 선정하였으며 이와 관련된 다양한 논문 및 기술보고서 등을 참고하여 리뷰를 수행하였다.

2. 주요 내용


본 연구에서는 위성영상의 구조와 대용량 자료 관리 방안에 대해 살펴보고자 대표적인 포맷인 HDF와 GeoTiff의 구조를 검토하였다. 여러 장의 위성영상은 매우 용량이 크며 체계적인 자료 관리가 필수적이기 때문에 array 데이터베이스 처리가 요구된다. 대용량 자료를 관리하기 위해서는 다차원 배열 데이터베이스(SciDB) 형태가 가장적합한데, SciDB의 구조를 이해하기 위하여 전통적인 DB관리 방안부터 가장 효율적으로 쓰이고있는 SciDB in-situ 방법을 검토한다. 또한 이러한 SciDB in-situ 방법을 이용하여 빅데이터 처리를 수행하고 있는 위성별(정지궤도위성, 고해상도 위성영상의) 서비스 제공 동향을 조사하였다. 마지막으로 국토위성센터의 배포관련 운영시스템 현황을 살펴보고 웹서비스 기술 개발을 위한 기초연구를 조사하였다.

가. 위성영상의 구조와 대용량 자료 관리 방안

1) 위성자료의 포맷(HDF, GeoTIFF) 및 구조

공간정보가 다양해지고 대용량화됨에 따라 수많은 포맷이 개발되고 있으며 일반 사용자가 위성 영상자료를 원활하게 사용하기 위해 HDF-EOS, GeoTiff 등 국제 영상자료의 표준화가 지속적으로 이루어져 왔다(이동한, 2008). 과학 기술 데이터를 분석하는 대부분의 분야에서는 일반적으로 HDF, NetCDF, MDSPlus, Root와 같은 과학 기술 데이터를 분석하고 관리하기 위한 데이터 포맷을 사용하고 있으며 MODIS(Moderate Resolution Imaging Spectroradiometer), GOCI(Geostationary Ocean Color Imager) 등 정지궤도 위성은 대용량 산출물을 효과적으로 저장, 배포하기 위해 HDF 자료 형식을 사용하고 있다. HDF(Hierarchical Data Format) 포맷은 계층적으로 구조화된 다차원 배열 데이터를 저장하기 위하여 HDF Group에 의해 만들어진 파일 형식으로, 현재는 HDF5 버전이 활용되고 있다(<https://www.hdfgroup.org/>)


HDF 파일은 이종의 데이터 객체(데이터셋)를 위한 컨테이너라고 할 수 있으며 데이터 셋은 이미지, 테이블, 그래프, 문서 등이 될 수 있다. HDF5는 그룹(Group), 데이터셋(Dataset), 속성(Attribute)로 구성되는데 그룹은 폴더, 데이터셋은 파일들로 비유 할 수 있으며 속성은 일종의 메타데이터로 그룹이나 데이터셋을 부연 설명하는 것을 의미한다. HDF 파일은 Root Group을 갖고 그림 9-1과 같이 하위에 다른 그룹을 포함하거나 다른 파일에 있는 객체에 연결되며 객체들은 서로 다른 그룹에 의해 공유 될 수 있다. 운영체제와 무관하게 사용할 수 있으며, 대용량 데이터를 빠르게 읽고 쓸 수 있는 특징이 있다.



<그림 9-1> HDF 파일 형식


데이터 셋은 실제 데이터 값들을 구조화 하며 그림 9-2와 같이 메타데이터(Metadata : Dataspace, Datatype, Attributes, Properties)와 데이터(Data)로 구성된다. 메타데이터의 Dataspace는 Null, 단일값(Scalar), 배열들로 구성되며 고정되거나 무제한의 차원을 가질 수 있

는 특징이 있기 때문에 다용도의 데이터 모델로 복잡한 데이터 객체 및 다양한 메타데이터를 표현할 수 있다. 데이터타입(Datatype)은 Integer, Float과 같이 단일 데이터 요소의 자료형태를 나타낸다. 속성(Attributes)은 기본적인 메타데이터 정보를 기술한다. 특성(Property)은 HDF5 객체의 성질이나 특징을 나타낸다.



<그림 9-2> 데이터 셋(Dataset) 구성 상세

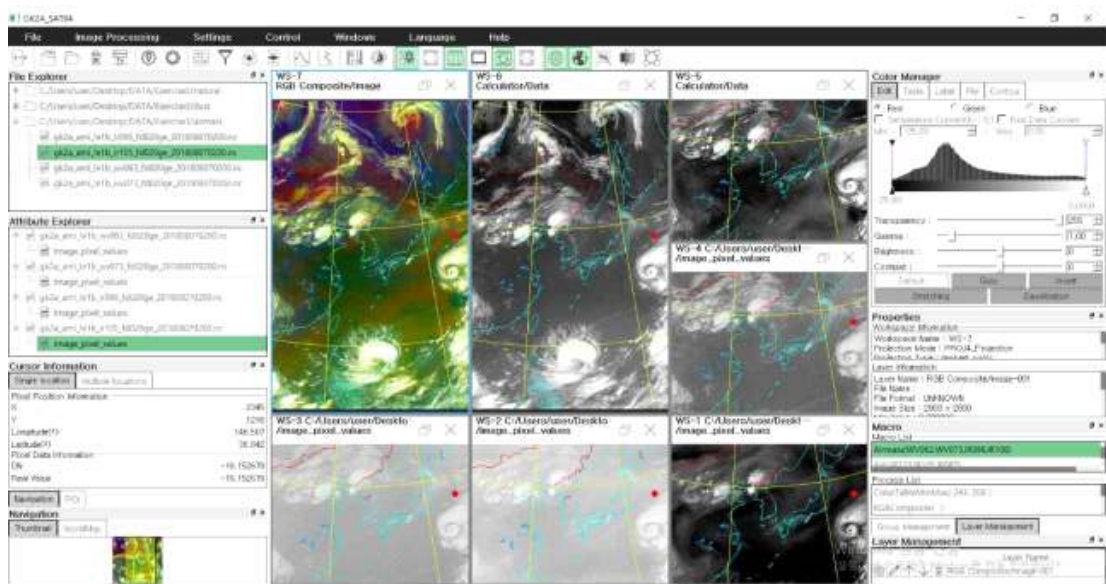
데이터셋의 저장 레이아웃을 정의하는 특성 값에 대한 예시를 그림 9-3에 나타냈다. 데이터 저장 시 기본값으로 Contiguous 값을 사용하지만, subset 기능을 통하여 성능을 향상하는 Chunked 옵션, 저장시 효율성 확장 및 전송 속도를 향상 할 수 있는 Chunked & Compressed 옵션을 선택할 수 있다.



<그림 9-3> 데이터 저장 layout 성능 향상 옵션

이러한 HDF5 형식의 위성자료는 범용 바이너리 및 텍스트 형태(.hdf, h5 등)로 제공되기 때문에 영상으로 확인하기 위해서는 영상으로 가시화하는 툴이 필요하다. 다양한 플랫폼에서 사용가능한 라이브러리 및 언어(C, C++, Java 등)를 지원하고 있으며, HDF Group에서는 정지궤도 위

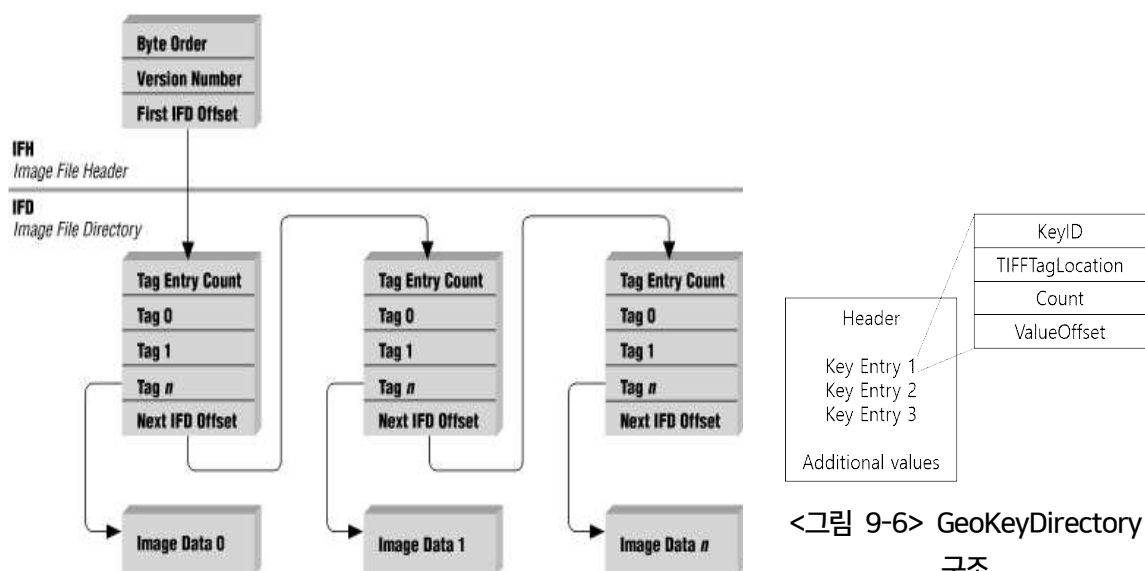
성에서 사용하는 HDF-EOS 파일의 데이터셋을 가시화 할 수 있도록 HDFView를 제공하고 있다. 천리안위성 (COMS/MI)의 경우 그림 9-4와 같이 HDF 기상위성 자료를 이용한 가시화 기능을 개발하여 사용자 맞춤형 영상처리 도구를 제공하고 있으며 국가기상위성센터 홈페이지에서 제공받을 수 있다(20.02.20 버전)



<그림 9-4> 천리안위성 사용자 맞춤형 영상처리 도구

영상정보와 항공사진 자료를 생산, 유통하는 국토지리정보원의 영상지도 제작에 관한 작업규정 (국토지리정보원 고시 제2009-949호 개정 2009.12.14.)에서는 제 10조(저장 및 보관) 항목을 통해 자동독취가 완료된 항공사진 영상은 최적 해상도로 저장하고 저장 포맷은 TIFF 또는 GeoTIFF 형식을 사용하는 것을 원칙으로 명시하고 있으며 고해상도 위성영상인 다목적 실용위성 시리즈 또한 GeoTIFF 포맷의 형태로 자료를 배포하고 있다(이동한 외, 2008). TIFF(Tagged Image File Format)는 가장 많이 사용되는 이미지 파일 포맷 중 하나인데 단순히 이미지 정보를 표출하는 것 외에 위성영상의 고유 정보를 제공할 수 있도록 위성정보, 밴드특성 등 사용자 정의 태그(Private Tag)를 기록한다. TIFF 파일 구조는 필수 구성요소인 IFH(Image File Header)와 IFD(Image File Directory) 그리고 영상데이터(Image Data) 부분으로 구성된다. TIFF 파일은 하나의 파일에 여러 밴드를 함께 저장되는 것이 가능하며 파일 구조는 그림 9-5와 같다. 헤더정보(IFH)는 8byte의 고정 위치를 갖고 폴더정보(IFD)와 함께 한 개 세트 구성되며 TIFF 6.0부터 영상데이터를 타일 형태로 저장할 수 있다. 타일은 전체 영상 중 일부를 이루는 작은 서브영상을 의미하며, 타일로 저장하면 가시화되는 영역만 불러와서 표출되기 수 있기 때문에 시스템 자원을 절약하면서 디스플레이 속도를 높일 수 있다(임정호 외, 2001). GeoTIFF라 불리는 파일형태는 지리정보를 갖는

TIFF6.0을 의미한다. 기존의 TIFF와 다르게 TIFF6.0 부터는 추가적인 사용자 정의 태그를 이용하여 위치정보를 표현할 수 있다는 특징이 있다. ModelPixelScale Tag, ModelTransformation Tag, ModelTiePoint Tag, GeoKeyDirectory Tag, GeoDoubleParams Tag, GeoAsciiParams Tag 총 6개의 추가적인 사용자 정의 태그가 추가되었으며 이 중 GeoKeyDirectory를 참조하여 TIFFTagLocation에서 값이 위치한 인덱스를 기반으로 지리정보를 표현할 수 있다(그림 9-6).



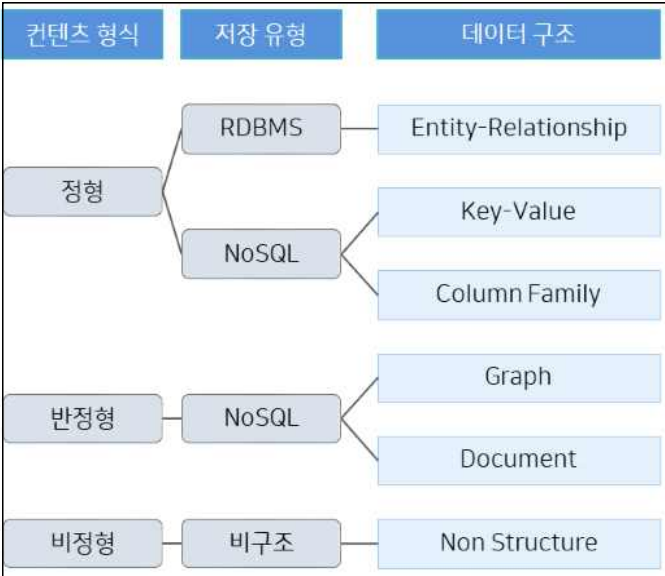
<그림 9-5> TIFF 파일 구조

<그림 9-6> GeoKeyDirectory 구조

2) 대용량 위성영상 자료 저장 및 관리 방안

빅데이터는 데이터가 많은 양(Volume), 빠른 속도(Velocity), 다양한 형태(Variety)로 생성되어 데이터가 방대해졌기 때문에 더 이상 전통적인 데이터 처리 시스템으로 처리하기가 어렵고 새로운 처리 기술을 필요로 하는 데이터 셋을 의미한다(권기태, 2014). 빅데이터를 분류하는데 있어 빅데이터의 유형에 따른 분류는 IBM과 UNECE(유엔유럽경제위원회)가 제시하는 ‘자료출처’ 및 ‘자료유형’ 기준에 따라 구분된다(정보화사회실천연합, 웹사이트). 이 중 데이터의 저장구조에 따라 정형, 반정형, 비정형으로 분류할 수 있다(그림 9-7). 정형 데이터의 저장방법은 CSV, 엑셀, XML 형식으로 이루어지며 사전에 정의되어 조직화되고 구조화된 데이터를 의미하기 때문에 정제된 데이터의 형태로 인해 검색 등의 데이터 처리에 용이하다는 장점이 있다. 비반정형 데이터는 고정된 필드에 저장되지 않는 데이터베이스나 스키마를 포함하는 XML, HTML, JSON과 같은 데이터

터를 의미한다. 정형 데이터는 고정된 필드에 저장되어 있지 않은 이미지, 사운드 등의 자료로써 미리 정해진 모델이 없으며 구조화되지 않은 데이터를 의미한다.



<그림 9-7> 데이터 구조 분류 체계

위성영상은 원천데이터의 수정이 쉽지 않은 비정형 데이터이며 대용량 위성영상을 활용함에 있어 데이터 검색 및 처리에 다수의 CPU, 메모리 디스크 등 많은 컴퓨팅 자원이 필요하기 때문에 컴퓨팅 리소스 사용의 확장성과 분산성에 대한 고려가 필요하다(한재웅 외, 2019). 대용량 위성영상은 데이터레이크를 구축하여 저장하고 빅 데이터 기술을 이용하여 처리 및 분석 연구를 진행하는 것이 효율적인데, 데이터레이크를 구축에 최적화된 저장구조 방안 중 하나가 SciDB이다. 데이터레이크(Datalake)란 개별 데이터를 원래의 형식으로 저장한 뒤 추후에 쉽게 분석할 수 있도록 설계한 저장소이다. SciDB는 대용량의 데이터에 대한 과학적 분석을 위해 개발된 오픈소스 데이터 관리 시스템으로 빅데이터와 방대한 분석에 최적화 되어 있다. SciDB를 이해하기 위하여 전통적인 DB관리 방법을 시작으로 데이터 관리 시스템의 발전 과정을 차례로 살펴보고자 한다.

전통적인 데이터베이스(DB)관리 방법으로 DBMS(Database Management System), 하둡(Hadoop) 등이 있으며 이후 Array DB 형태로 발전하였다. DBMS는 DB 관리를 효율적으로 할 수 있도록 도와주는 시스템으로 데이터 집합(DB)을 만들고, 데이터베이스에 접근할 수 있는 언어(SQL, Structured Query Language)로 데이터를 조작하는 일련의 과정을 제공한다. DB의 구조적 차이에 따라 관계형 데이터베이스(Relational Database), 키-값 데이터베이스(Key-Value Database), 객체형 데이터베이스로(Object Database)로 분류하는데, 이 중 관계형 데이터베이스시스템

(RDBMS)이 상업용으로 가장 많이 활용하며 대표적으로 MS-SQL Server(Microsoft), MySQL (Oracle) 등이 있다. 정형화된 데이터를 기반으로 데이터 표준화에 강점이 있으며 검색의 최적화를 위한 인덱스 기능을 제공하지만, 데이터 저장에 유연성이 부족하다. 또한 주로 1차원의 자료를 취급하고 배열 관련 연산기능이 없다. 빅데이터의 유연하고 확장성을 갖춘 DB 관리를 위하여 하둡(Hadoop)을 활용할 수 있다. 하둡은 여러 컴퓨터에 대용량 데이터를 분산 저장 및 분석 처리하는 오픈소스 소프트웨어 프레임워크이다. 데이터베이스의 유형으로 비정형 DB를 활용하고 구조를 정의할 필요 없이 데이터를 저장하고 검색할 수 있으며 저장되는 구조가 고정되지 않아 유연하게 저장할 수 있다. 또한 전통적인 관계형 데이터베이스와 달리 데이터를 저장하기 전에 전처리가 필요 없고 구조화되지 않은 데이터를 처리할 수 있으며 분산 처리 환경에서 대용량 데이터 처리 및 분석을 지원한다. 빅데이터를 저장하고 데이터를 빠르게 처리할 수 있는 파일 시스템으로 HDFS(Hadoop Distributed File System)를 사용하는데 HDFS는 분산 시스템 환경에서 일부 데이터를 사용할 수 없게 되어도 다시 처리할 수 있도록 각 데이터를 복제하여 저장한다. 그러나 전통적인 방법의 DB관리 방법들은 대부분 배열(Array)로 표현되는 과학 기술 데이터를 효율적으로 처리하지 못하는 한계점이 있다.

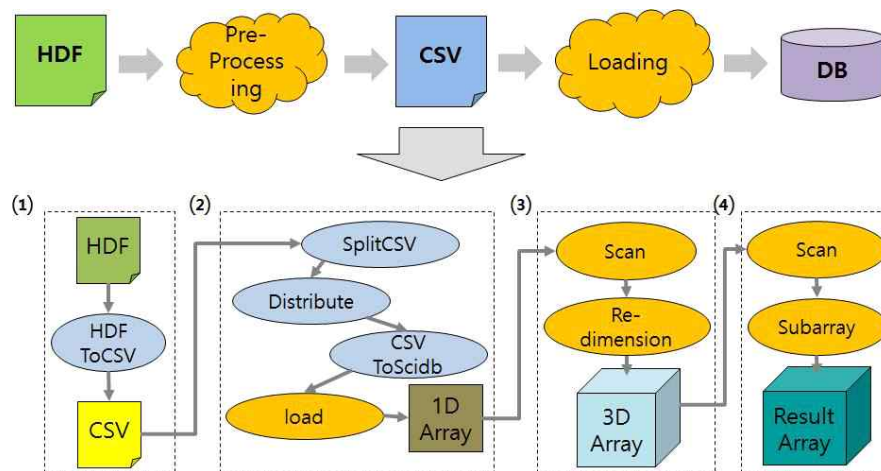
위성 자료는 CCD 배열이 장착된 카메라로 촬영하게 되며 수많은 객체들을 포함하는 영상을 촬영하는데, 영상에서 각 픽셀의 값은 인접한 점이라도 각각 다른 의미를 갖기 때문에 센서 배열을 통해 얻어진 값들은 데이터들의 배열이 된다. 일반적인 데이터와 다르게 과학적인 데이터는 센서 배열(Sensor Arrays)을 통해 측정된 정보를 다루기 때문에 배열형 데이터베이스 시스템을 통해 데이터를 저장하고 관리되어야 한다. 대표적 배열형 DBMS(Array DBMS)은 GeoRaster, PostGIS, SciDB 등이 있으며 이 중 SciDB는 대규모 과학 데이터를 처리를 위한 대표적 DBMS로 쓰이고 있다(최종혁 외, 2015).

SciDB(다차원 배열 데이터베이스)는 2008년 개발되었으며, 대용량 데이터의 과학적인 분석을 위하여 개발된 분산 클러스터 기반의 배열 데이터베이스 관리 시스템이다(김미정 외, 2018). 배열형 데이터 모델을 이용하여 처리하는데, 기존의 관계형 DBMS에서 사용하는 1차원 배열을 활용하여 저장할 수 있는 확장성을 갖고 있으며 다차원의 배열로 시계열 자료를 효과적으로 표현할 수 있다. 뿐만 아니라 기존의 관계형 DBMS와 처리시간 비교 분석 결과, 과학 데이터 처리에 보다 뛰어난 처리 속도를 확인할 수 있다(그림 9-8).

DBMS	Dataset	Loading/Cooking [min]				Query Runtimes [min]									
		Load	Obsv	Group	Total	Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Q9	Total
MySQL	small	760	110	2	872	123	21	393	0.4	0.36	0.6	0.6	49	50	638
	normal	770	200	90	1060	54	44	161	50	32	51	52	305	305	1234
	(scaleup)	(1.0)	(1.8)	(45)	(1.2)	(0.4)	(2.1)	(0.4)	(125)	(89)	(85)	(87)	(8.1)	(7.9)	(1.93)
SciDB	small	34	1.6	0.6	36	8.2	0.2	3.7	0.007	0.01	0.01	0.01	1.8	1.9	16
	normal	67	1.9	15	84	3.6	0.07	1.7	0.015	0.017	0.02	0.11	2.2	2.3	10
	(scaleup)	(2.0)	(1.2)	(25)	(2.3)	(0.4)	(0.4)	(0.4)	(2.1)	(1.7)	(2)	(11)	(1.2)	(1.2)	(0.63)
(MySQL/SciDB)	small	(22)	(69)	(3.3)	(24)	(15)	(105)	(106)	(57)	(36)	(60)	(60)	(27)	(26)	(40)
	normal	(12)	(105)	(6)	(13)	(15)	(630)	(95)	(3330)	(1880)	(2530)	(470)	(180)	(170)	(120)

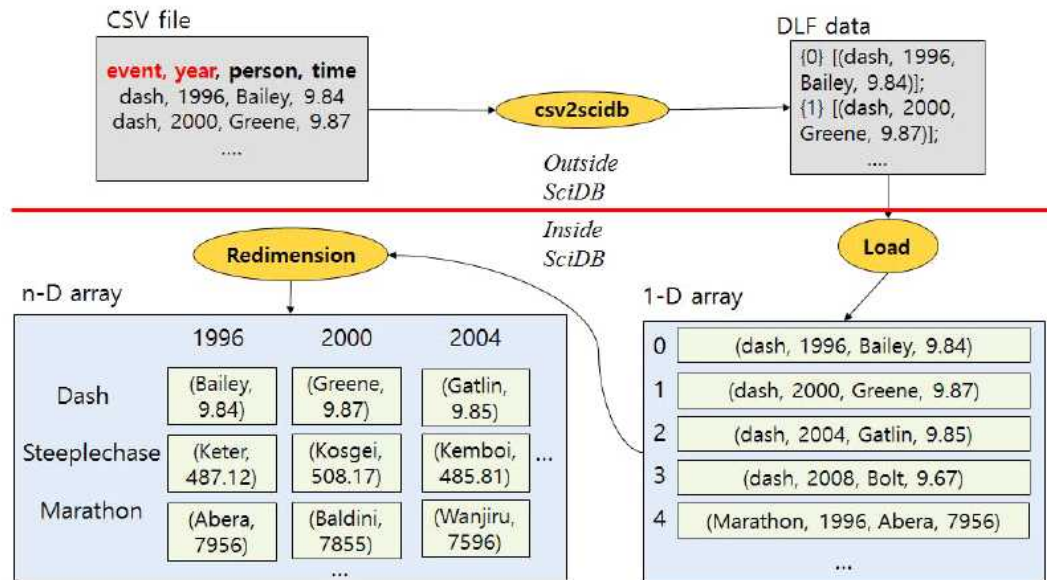
<그림 9-8> 관계형 DBMS(MySQL)과 SciDB 데이터 처리 시간 비교 분석(최종혁 외, 2015)

SciDB는 그림 9-9와 같이 과학 기술 데이터를 로딩하기 위해 CSV와 같은 중간 데이터 포맷으로 변환해야하는 전처리 과정이 필요하다. HDF와 같은 과학 기술 데이터를 SciDB에 로딩하기 위하여 CSV 파일로 변환하는 과정을 말하는데, 이 과정에서 다차원 array 스키마를 가지는 과학 기술 데이터는 1-D array 스키마로 변환 되므로 차원에 따라서 데이터들이 정렬 되어있는 것과 같은 다차원 array가 가지는 특성들을 손실하게 된다.



<그림 9-9> SciDB에 데이터를 로딩하기 위한 과정

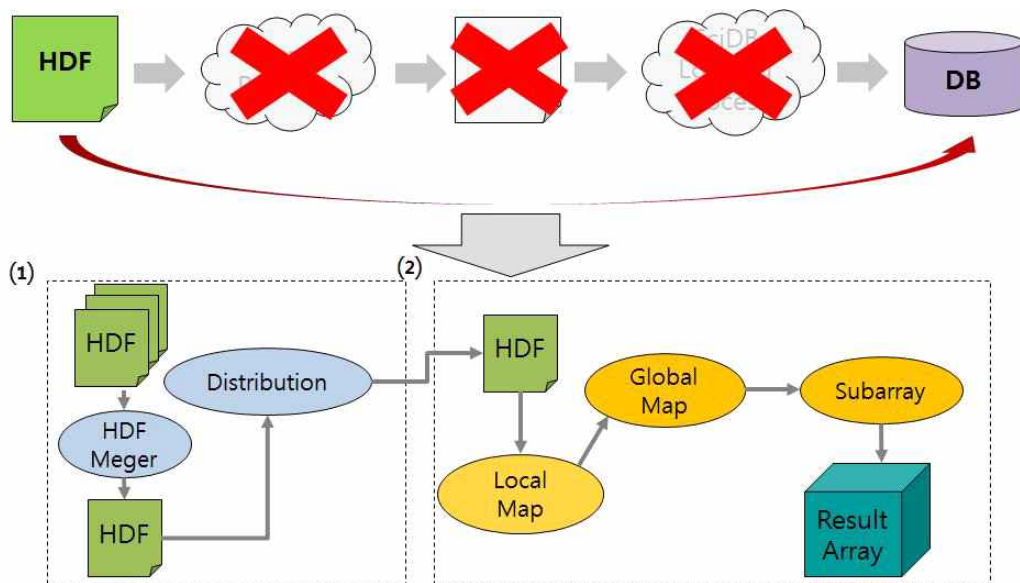
그림 9-10과 같이 손실된 스키마는 SciDB에 로딩 과정 중에 복구 하게 되며 그 과정을 Re-dimension 이라고 하며, 배열의 차원과 속성을 재설정하는 연산으로 3차원 배열 데이터가 1차원 상태로 배열이 입력되었을 때 SciDB 내에서 다시 3차원 상태로 변환하는 과정을 수행한다 (김태훈, 2017).



<그림 9-10> SciDB 로딩 방법 예시(한국과학기술정보연구원, 2015)

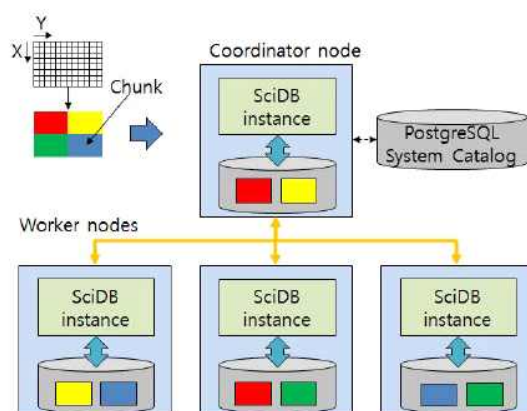
많은 양의 전체 데이터를 모두 사용하기보다 실제 관심있는 일부 부분만을 추출하여 연구에 사용하는 것이 더 효과적인데, 배열 검색 언어인 AQL(Array Query Language)을 활용하면 좌표나 속성에 대한 특정 조건을 입력하여 필터 연산을 수행할 수 있으며 영상 데이터를 효과적으로 관리할 수 있다. 시공간적 위치에 따라 탐색하고 모델링하여 시뮬레이션을 수행한 결과를 연구 목적에 맞게 가시화 하는 작업을 반복적으로 수행할 수 있을 뿐 아니라 영상 데이터를 고속으로 탐색 할 수 있다(한국과학기술연구원, 2017). 그러나 Array DB 관리 방법에도 한계점이 존재한다. 관심 영역만 분석하고자 하는 경우에도 모든 데이터를 로딩하는 과정이 필요하며, 데이터가 모두 로딩 하는데 오랜 시간이 소요된다는 점이다. 이러한 한계점을 개선하여 SciDB In-Situ 형태로 발전하였는데 불필요한 데이터 로딩을 피하면서 데이터가 데이터베이스에 로드 되어있는 것처럼 수행할 수 있도록 개선되었다.

SciDB에 적용된 in-situ 분석은 CSV 파일로 변환해야 하는 전처리 과정이 없이도 SciDB에서 AQL 기반 조건 입력(질의)를 통해 빠르게 자료를 불러올 수 있다. 그림 9-11의 (1), (2) 과정은 데이터 로딩 없이 SciDB에서 처리하는 과정이다. CSV 파일 변환하거나 DB에 적재하는 과정 없이 데이터 파일 상에서 조건을 처리하고 즉시 분석할 수 있는 기능을 지원한다.



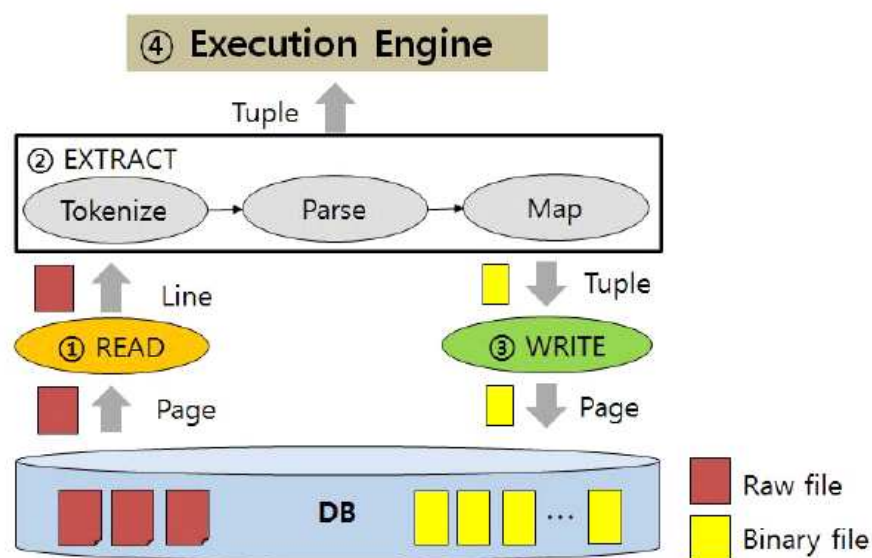
<그림 9-11> SciDB에 적용된 in-situ 분석 과정

그림 9-11에서 (1) 과정은 여러개의 위성영상 자료(HDF)를 한 개의 HDF 파일로 병합하는 작업과 병합된 파일들을 SciDB instance로 분산하는 작업으로 구성된다. array 데이터를 분할하여 여러곳에서 저장하는데, sub-array 형태인 chunk로 저장된다. SciDB에서 배열 검색 언어인 AQL로 입력한 처리 조건을 수행하기 위해서는 그림 9-12와 같이 Coordinator node와 Work node로 나누어 조건을 처리한다. Coordinator node는 SciDB에 로딩된 데이터인 모든 Chunk에 대한 맵핑 정보를 관리하며, Work node는 각 노드에 저장되어 있는 Chunk들을 이용하여 질의를 수행한다. 각 노드에는 SciDB instance라는 SciDB를 동작하기 위한 프로세스 그룹이 있으며 독립적으로 수행된다.



<그림 9-12> SciDB 구조

그림 9-13과 같이 일반적인 DBMS 로딩과정은 ①Read → ②Extract → ③Write 단계를 실행하게 되는데 SciDB in-situ 방법은 External tables 분석 방식을 사용하여 Write 단계를 거치지 않고 바로 처리 엔진(④Execution Engine)으로 데이터를 전달한다. External Tables 방식은 실제 데이터는 데이터베이스에 로딩되지 않게 생성하여 데이터베이스 외부에 저장되어있으며, CSV 포맷의 데이터가 마치 데이터베이스 안에 로딩 되어져 있는 것처럼 사용 할 수 있도록 하는 방법이다.



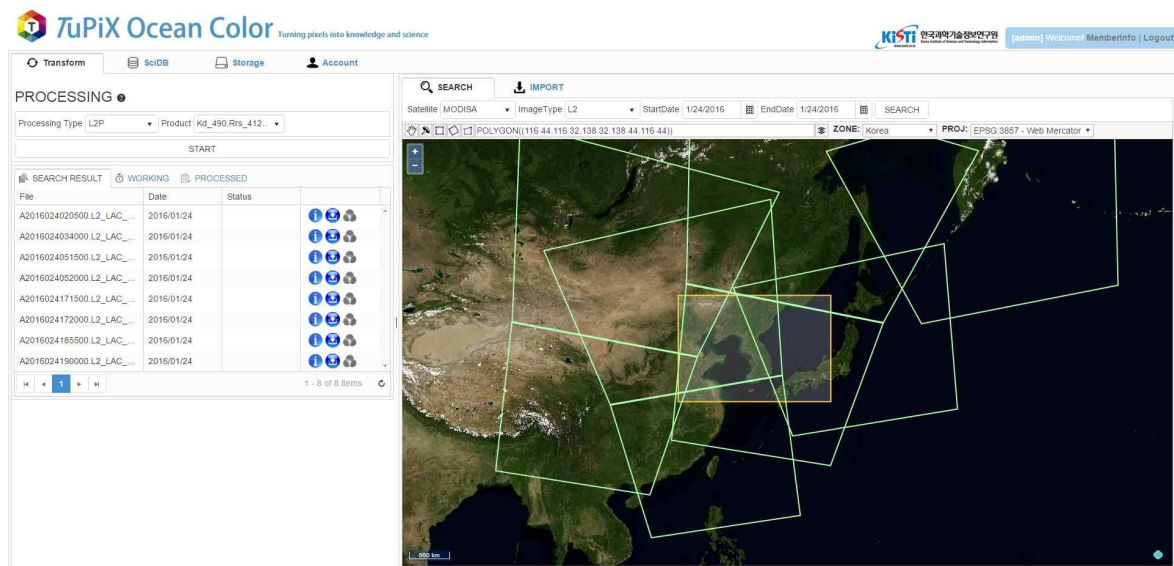
<그림 9-13> SciDB의 데이터 로딩과정

SciDB에 적용된 in-situ 분석 방법은 저장소에 있는 모든 데이터를 로딩하지 않고도 특정 지역과 특정 기간에 대한 데이터를 분석할 수 있기 때문에 편의성이 뛰어나며, 질의에 따라 데이터로딩에 비해 60배 이상의 성능을 개선한다(한국과학기술연구원, 2015).

나. 빅데이터 처리 기반 위성별 서비스 제공 동향

1) 정지궤도 위성 영상 빅데이터 처리 및 서비스 제공 동향

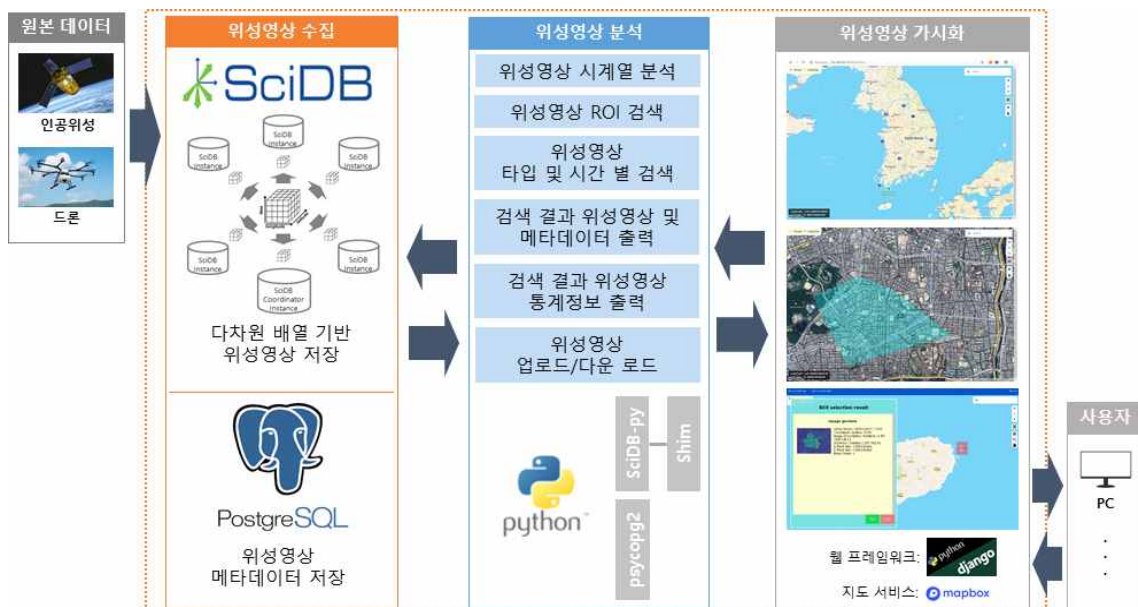
정지궤도는 위성이 지구 주변을 도는 공전 속도와 지구가 자전하는 속도가 일치해 늘 지구의 같은 곳을 바라보기 때문이 기상 관측이나 통신 중계 등에 주로 활용된다. 매일 반구 및 전구의 형태로 관측하고 있으며 기상위성의 경우(천리안위성 2A) 동아시아는 10분, 한반도 영역은 2분 간격으로 관측한다. 또한 52종의 기상산출물을 생산하기 때문에 매일 축적되는 위성관측 영상데이터 양이 상당하다. 이러한 원시 영상을 단일 PC를 기반으로 분석하기에는 데이터 전처리 및 분석에 많은 시간이 소요되며 한국과학기술연구원에서는 이를 개선하기 위한 연구를 추진하였다. 2016년 대용량 위성영상 데이터 분석처리 시스템 SW배포 패키지를 개발하였고, 이를 통해 클러스터 기반의 병렬처리 기술 및 다차원 배열 데이터베이스(SciDB) 시스템 기술을 활용한 위성영상 데이터 분석 플랫폼을 개발하였다. 해당 플랫폼은 통합 과학데이터 분석환경을 통해 과학데이터의 공유 및 분석이 가능하며 웹기반의 통합 분석환경을 통해 데이터의 전처리부터 가시화, 분석까지 단일화된 UI로 제공한다(한국과학기술정보연구원 2013). 또한 그림 9-14와 같이 빅데이터 분석 시스템인 TuPiX 기술을 적용하여 클러스터와 같은 빅데이터 처리 환경에서 데이터 처리 및 분석에 소요되는 시간을 줄여 기존의 상용 빅데이터 플랫폼보다 빠른 다차원 빅데이터 분석을 수행한다(한국과학기술정보연구원 2018).



<그림 9-14> TuPiX 기반 대용량 고해상도 위성데이터 처리(KISTI 보도자료, 2016)

2) 고해상도 위성영상 빅데이터 처리 및 서비스 제공 동향

아리랑 위성(KOMPSAT)은 약 55cm급의 고해상도 위성영상으로써 영상 한 장(L1R)에 1GB가 넘는 대용량의 자료가 수집된다. 국토위성 또한 50cm의 고해상도 영상을 취득하며 1일 촬영(25분, 175장)영상을 기준으로 약 100GB의 표준영상(L1R)이 취득된다. 국토위성센터가 대용량 위성영상을 가공하여 정밀정사영상(L2) 및 활용산출물을 제공하는데 있어 대용량 처리 기술의 도입은 필수적이다. 아리랑 위성을 운영하는 한국항공우주연구원은 급격하게 증가하는 대용량 위성정보 데이터의 운영을 위해 위성영상에 적합한 빅데이터 플랫폼을 개발하였다(한국항공우주연구원 2018). 확장성을 고려한 분산구조 대용량 위성영상 저장 및 위성영상에 적합한 빅데이터 처리 기술 검토를 통해 위성영상 가시화 기술을 개발하였으며 정지궤도위성 플랫폼 개발에 적용한 기술과 동일하게 고해상도 위성영상 플랫폼에서도 다차원 배열 데이터베이스(SciDB)를 적용하였다. SciDB 적용을 통해 대용량의 위성영상을 효율적으로 저장 및 검색하고 웹기반으로 원하는 지역을 조회하고 인공지능 분석 모듈과 연동한다. 최근에는 위성영상 빅데이터 처리 및 분석 시스템 성능 개선 및 안정화(한국항공우주연구원 2020) 추진을 통해 SciDB 버전을 업그레이드하고 지원하는 위성영상의 종류를 추가하였다.



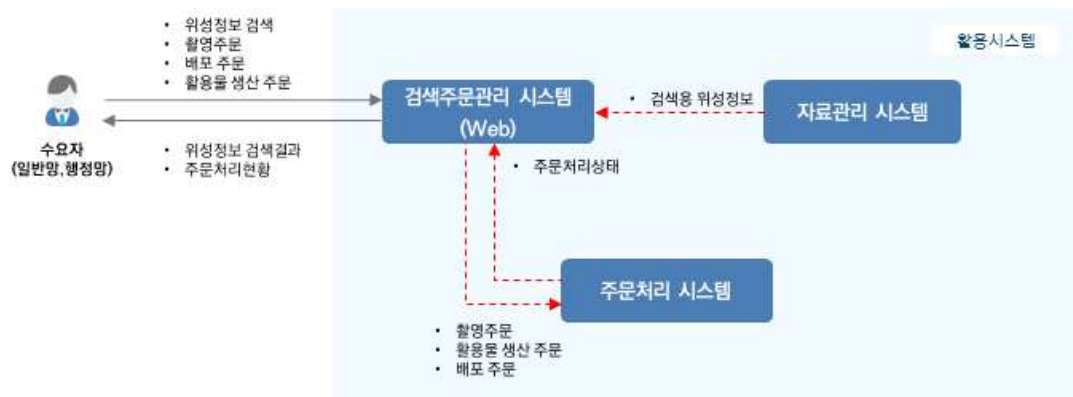
<그림 9-15> KARI 빅데이터 처리 및 분석시스템 구성도(한국항공우주연구원, 2020)

다. 고해상도 위성영상 서비스 제공 방법

1) 국토위성 웹서비스 제공 방법

국토위성센터는 국토위성을 수집하고 활용하기 위하여 지상국 시스템을 운영하고 있으며, 위성영상의 안정적인 수집 및 저장을 위하여 약 8PB의 저장장치를 도입하고 저장관리 시스템을 이용하여 자료를 관리한다. 저장관리 시스템은 촬영주문, 영상처리 주문을 기반으로 표준영상생성 시스템과 정밀영상생성 시스템으로 위성정보생성을 요청하고, 생성된 위성정보를 NAS 저장장치에 저장하고 웹 표출용 카탈로그를 저장하고 관리한다. 수집된 모든 국토위성 자료(L0F, L1R) 및 산출물(L2G, 활용산출물 등)은 DBMS로 관리한다.

수요자가 요청하는 위성정사영상 생성 및 활용 산출물 배포 관련 시스템의 처리 흐름은 다음과 같다. 위성영상 서비스와 관련해서는 검색주문관리 시스템, 배포관리 시스템, 주문처리 시스템, 배포처리 시스템, 자료관리 시스템이 구축되어있다. 검색주문관리 시스템은 그림 9-16과 같이 자료관리 시스템의 국토위성 DB와 연동되어 운영된다. 수요자의 촬영주문기능과 활용 산출물 주문 기능을 제공 하는 웹 서버가 설치되어 있으며 수요자 요청에 대해 효율성을 높이기 위하여 다중 서버를 활용하여 분산 처리 구성을 하였다. 주문처리 시스템은 수요자가 주문한 촬영·활용산출물에 대한 주문정보를 처리하여 배포시스템으로 전달한다.



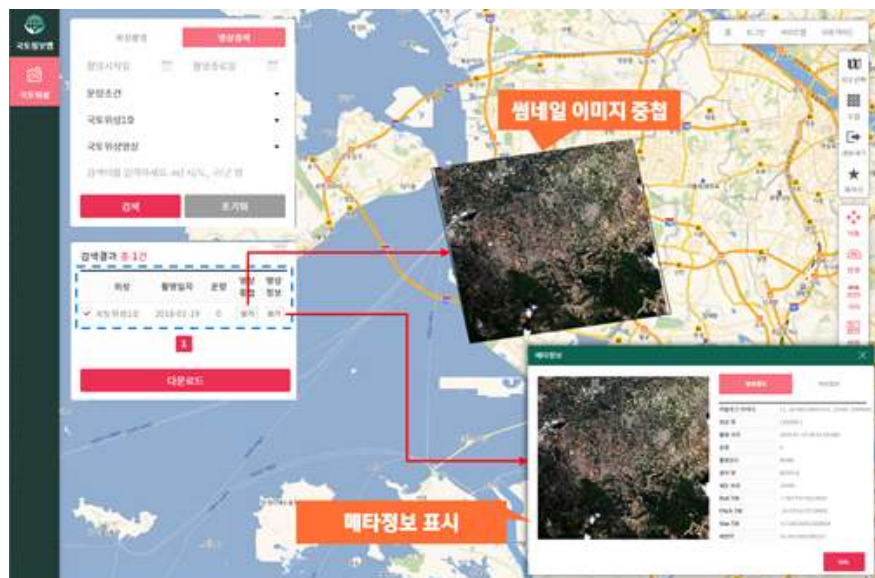
<그림 9-16> 검색주문관리 시스템 데이터 처리 흐름도

배포관리시스템은 그림 9-17과 같이 국토위성의 표준영상, 정밀영상, 활용산출물을 Web다운로드 서비스, FTP다운로드 서비스 및 오프라인으로 배포하는 시스템으로, 배포처리 시스템을 통해 처리된 위성산출물을 수신하여 웹서비스 배포물로 등록한다.



<그림 9-17> 배포관리 시스템 데이터 처리 흐름도

위의 과정을 거쳐서 생산된 산출물들은 국토정보플랫폼에서 조회가 가능하며 카탈로그 이미지 검색을 통해 영상을 조회하고 원하는 영상을 제공받을 수 있다. 카탈로그 이미지는 1024×1024 픽셀크기로 제작되어 지도에 표출하는데, 사용자가 입력한 조건에 해당하는 카탈로그를 저장관리 DBMS에서 검색하여 정보를 목록으로 조회하고 그림 9-18과 같이 배경지도 위에 가시화한다.




<그림 9-18> 국토정보플랫폼 국토위성 검색 화면


현재 국토위성 웹 서비스 방법은 산출물에 대한 검색조건 입력을 통해 Scene 단위(12km × 12km)로 영상을 제공한다. 제공하는 한 장(Scene)당 용량이 너무 크기 때문에 웹 사이트에서 국토위성영상 자체를 표출하는 것은 제약이 있으며, 파일의 크기가 작고 영상의 상태를 확인할 수 있는 카탈로그 이미지를 만들어 제공하고 있다. 국토정보플랫폼을 통해 영상 제공 요청시 지상국 시스템을 기반으로 배포 산출물을 생성하고 영상 요청에 대하여 TIFF 파일 형태로 산출물을 제공한다. 현재는 DB관리가 관계형 DBMS로 관리되고 있으나 향후에는 앞서 설명한 SciDB 등의 저장 관리 방안을 검토하여 대용량 영상정보의 저장 관리 효율성 향상이 필요할 것으로 판단된다.

2) 대용량 위성영상 가시화 및 웹서비스 방법

앞서 살펴본 것과 같이 SciDB는 대용량의 위성영상 자료를 처리에 유용한데, 배열형태의 저장 구조를 갖고 과학에 특화된 기본 연산 제공, 분산처리 시스템 등의 특징이 있다. SciDB에서 사용 가능한 기본 연산자를 이용하여 위성영상의 시각화하는 연구도 진행되어 왔으며, 그림 9-19와 같이 SciDB에 저장된 데이터는 질의를 이용하여 시각화에 용이하게 가공되고 MATLAB, GeoServer 등으로 시각화하게 된다. SciDB는 배열 질의 언어(AQL, Array Query Language)와 배열 함수형 언어(AFL, Array Functional Language)을 제공하고 하고 있으며 해당 기능을 활용하여 그림 9-20과 같이 일정 범위의 값을 계산하고 추출할 수 있다(최종혁 외, 2015).

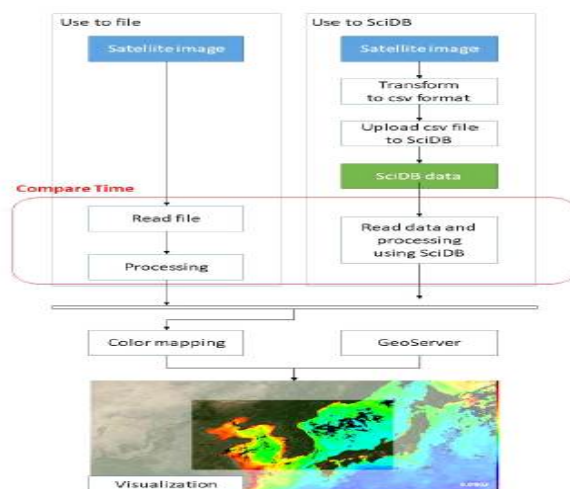


<그림 9-19> 위성영상 가시화 흐름도(예시)



<그림 9-20> AQL 기반 SciDB 가공(예시)

그림 9-21은 원본 MODIS 위성영상을 이용한 시각화 방법과 SciDB 기반 질의를 통해 시각화하는 방법을 비교한 흐름도이다(김미정 외, 2018). 원본 MODIS 영상을 그대로 읽어서 처리할 경우 많은 시간이 소요되었으나, SciDB 기반 AQL을 이용한 경우에는 연구지역을 지정하고 해당 지역에 대한 연산 수행 후 데이터를 읽어오기 때문에 별도의 처리 과정이 필요하지 않았으며 표출 속도가 기존 방법보다 더 빠르게 나타났다. 한 개 영상만 처리하는 것이 아니라 대용량 시계열 위성영상을 처리하는데 있어 SciDB를 이용하는 것이 효율적일 것으로 기대된다.



<그림 9-21> 위성영상 시각화방법 비교 흐름도

이와같이 빅데이터 영상처리를 수행하고 산출된 대용량 GeoTIff 자료를 웹으로 서비스하기 위해서는 공간정보 웹 서비스 표준을 적용하여 제공해야 한다. 웹 프레임워크란 시스템 개발에 있어 필요한 공통적인 부분을 제공해주는 구조화된 개발 틀을 뜻하는데, 표준프레임 워크를 기반으로 구축해야 서로 다른 시스템이라 하더라도 표준을 따르는 경우 시스템 내에 구축된 각각의 공간정보에 대한 공유와 상호 운영과 정보처리가 가능하다(윤구선 외, 2015). 국제표준화 기구 OGC(Open Geospatial consortium, Inc)에서 정의하는 공간정보 웹 서비스 표준 사양으로는 Web Map Service(WMS), Web Feature Service(WFS), Web Processing Service(WPS), Web Map Tile Service(WMTS) 등이 있다. 위성영상 정보처리를 위한 오픈소스 엔진으로는 GeoServer가 대표적이다. 커뮤니티 기반 프로젝트에 의한 java로 개발된 GIS 오픈소스이며 다양한 위성영상처리 알고리즘을 제공한다. 대용량 위성영상 자료를 웹으로 제공하는 방법으로는 Geoserver에서 WMS 서비스 제공, WMTS 제공 방법, 타일맵을 만들어 TMS 레이어로 서비스 하는 방법 등이 있다. 타일맵을 만들어 서비스 하는 대표적 사례가 네이버 지도 서비스이다. 사용자들이 보고 있는 한 장의 지도 화면은 하나의 이미지 파일(256픽셀 X 256픽셀)에 해당하는 이미지 타일을 조합하여 하나의 지도 화면으로 보여주는 것이다. 실제 거리 대비 픽셀을 기준으로 지도의 크기를 나타내는데, 1레벨에서부터 14레벨까지 총 14단계의 값을 사용하며 그 표현 범위는 그림 9-22와 같다.



<그림 9-22> 각 레벨별 이미지 타일 구성(출처: 네이버 D2 블로그)

3. 결론 및 기대효과

대용량의 위성영상을 효율적으로 관리 및 활용하기 위해 기본이 되는 위성영상의 저장 구조를 조사하고 SciDB 기반의 위성영상 처리 방법과 이를 이용한 영상 빅데이터 처리 및 서비스 제공 동향을 살펴보았다. 현재 국토위성의 운영시스템은 촬영된 위성영상을 카탈로그 형식으로 관리하며 대용량 영상의 용량을 줄여 미리보기 영상을 생성하고 표출하고 있다. 향후에는 SciDB, 다양한 빅데이터 처리 기법이 고려된 대용량 영상 분석이 수행되어 위성영상 검색 및 표출 등이 빠르게 수행될 수 있을 것으로 기대한다. 또한 다양한 국토위성 산출물들이 즉시 시각화되고 웹 기반으로 즉각적으로 제공됨으로써 국토위성영상을 원하는 사용자에게 신속히 제공 할 수 있는 환경이 마련 될 수 있을 것이다.

참고문헌

- 김미정, 김대성, 박귀몽, 김태영, 최명진, & 박정희. (2018). SciDB 를 이용한 해양위성영상
권기태. (2014) 빅 데이터 소프트웨어 비용산정을 위한 FP 응용. 한국소프트웨어감정평가학회
10(2)
- 가시화. 한국정보과학회 학술발표논문집, 1602-1604.
- 김태훈. (2017). 대용량 과학데이터에 대한 저용량 필터링 기법 (Doctoral dissertation,
서울대학교 대학원).
- 최종혁, & 이종연. (2015). Array DBMS 을 이용한 위성원격탐사 영상의 3 차원 시각화.
Journal of Digital Convergence, 13(2), 193-204.
- 한국과학기술정보연구원 (2013), 과학기술 빅데이터 공유·융합체제 구축
- 대구경북과학기술원 (2015), 분산 환경 기반의 과학 기술 데이터 in-situ 분석
- 한국항공우주연구원 (2017), 위성영상자료처리 고속화를 위한 최신 병렬처리 기술 및 병렬처리
하드웨어 연구
- 한국과학기술정보연구원 (2017), 과학기술 빅데이터 공유·융합체제 구축
- 한국항공우주연구원 (2018), 위성영상 빅데이터 플랫폼 데이터 모델링 개선 및 성능시험
- 한국항공우주연구원 (2018), 위성영상 빅데이터 기술 성능시험 및 가시화 시제품 제작
- 한국과학기술정보연구원 (2018), 다차원 빅데이터 분석기술(TUPIX)
- 한국항공우주연구원 (2020), 위성영상 빅데이터 처리 및 분석 시스템 성능 개선 및 안정화
- 한상혁, 한재웅, & 주광혁. (2019). 항공우주용 빅데이터 처리 및 분석기술 개발 현황. 한국항
공우주학회 학술발표회 초록집, 188-189.
- 윤구선, & 이기원. (2015). 웹 처리 서비스 (WPS) 표준의 위성영상 정보처리 시험 적용. 대한
원격탐사학회, 31(3), 245-253.
- 윤구선, & 이기원. (2015). 클라우드 컴퓨팅과 웹 프레임워크 환경에서 WPS 기반 위성영상 정
보처리. 대한원격탐사학회지, 31(6), 561-570.
- 이동한, 서두천, & 임효숙. (2008). 고해상도 위성 영상자료 표준화 동향. 항공우주산업기술동
향, 6(2), 31-39.

- 이기원, & 강혜경. (2010). 공간영상정보 관련 ISO 와 OGC 표준현황과 활용을 위한 제언. 대한원격탐사학회지, 26(4), 451-464.
- 이기원, & 강혜경. (2010). 공간영상정보 관련 ISO 와 OGC 표준현황과 활용을 위한 제언. 대한원격탐사학회지, 26(4), 451-464.
- 한재웅, & 한상혁. (2019). 위성-드론 항공우주 빅데이터 처리를 위한 자료 저장 시스템 설계. 한국항공우주학회 학술발표회 초록집, 524-525.
- 한상혁, 한재웅, & 주광혁. (2019). 항공우주용 빅데이터 처리 및 분석기술 개발 현황. 한국항공우주학회 학술발표회 초록집, 188-189.
- 한국항공우주연구원, 과업지시서, 위성영상 데이터 기반 도시분석 인공지능 기술 개발 및 빅데이터 처리 시스템과의 연동, 2020

HDF 파일 형식 설명, <https://blog.naver.com/estern/220744607704>

HDF5 형식의 데이터 파일 읽기, <https://blog.daum.net/swrush/577>

Harriss 홈페이지 www.l3harrisgeospatial.com/docs/HDF5_Overview.html

정보화사회실현연합 웹사이트 <https://www.cisp.or.kr/archives/22015>

KISTI 보도자료, 70배 빠른 다차원 빅데이터 분석 기술 개발 성공, 2016

제10장

딥러닝 기반 건물 객체탐지 기초기술 개발

1. 연구의 배경 목적
2. 주요 내용
3. 결론

1. 연구의 배경 및 목적

국토교통부는 2015년부터 국토위성센터의 설립과 국토위성 기반 다양한 활용산출물 제공을 위한 연구를 추진했고, 활용 산출물(안)으로 정밀정사영상, 변화탐지, 객체추출, 주제도 제작 등을 선정하며 관련 연구 및 시스템 개발을 추진하였다. 2018년부터 국토위성정보 수집 및 활용시스템 개발('18~'20) 과제(이하 2018 R&D 과제)를 진행하며 국토위성 수집·활용 시스템을 개발함과 동시에, 딥러닝(deep-learning) 등 최신 기술을 위성영상 분석에 적용하여 건물, 도로 추출 등에 시범 적용하는 연구를 수행하였다. 2018 R&D 과제를 통해 개발된 딥러닝 기반의 건물, 도로 등 객체추출 기술은 핵심 기술개발을 위한 연구과제 형태로 기술 적용 가능성 여부 확인 등을 위한 시범 적용에 불과한 수준으로, 바로 현업에 적용해 활용하기에는 한계가 있다.

위성영상의 해상도가 지속적으로 향상됨에 따라, 위성영상으로부터 도로, 건물, 산림 등 주요 관심 객체에 대한 유의미한 정보를 탐지추출할 수 있는 영상분류 및 객체탐지 기술이 지속적으로 발전하고 있다. 대표적인 영상 분류 및 객체 탐지 기법으로 화소기반, 객체기반 방식이 있다. 화소기반 객체 탐지의 경우 해상도가 증가할수록 건물의 그림자, 도로 내 차량 및 차선 등으로 인해 건물, 도로 등의 객체 탐지 정확도가 감소하며, 객체기반 탐지의 경우 고해상도 위성에서 건물, 도로 등의 객체 탐지에 상대적으로 정확도가 높으나, 다양한 형태의 공간객체에 대한 탐지 정확도를 보장할 수 없는 단점이 있다(송창우 등, 2020). 반면 딥러닝을 통한 객체 추출의 경우, 과거 데이터 트레이닝 등에 오랜 시간이 소요되었지만, 최근 컴퓨팅 성능의 개선 등을 바탕으로 트레이닝 및 분석 시간이 현저하게 줄어든 상황이다. 이에 따라 짧은 시간과 높은 분류정확도를 제공하는 다양한 딥러닝 기반 객체탐지 연구가 활발하게 수행중이다(이대건, 조은지, 이동천, 2018). 국토위성센터는 국토위성이 촬영한 영상의 분석, 가공을 통해 다양한 산출물 제공을 위한 방안을 마련 중으로, 건물 탐지의 경우 수치지도의 갱신, 과거 촬영된 영상과의 변화정보를 통한 도시개발 현황 파악, 재난재해 피해분석, 불법 건축물 탐지, 개발제한 구역 모니터링 등 다양한 현업 분야에 활용 될 수 있어 딥러닝 기반 객체추출의 지속적인 연구와 기술 개발 및 정규 산출물 제공 체계 구축 등이 필요한 상황이다.


현재까지 진행된 딥러닝 기반의 건물탐지 연구는 단일 센서로 촬영한 영상만을 활용하여 딥러닝 트레이닝을 진행하고 그 성능을 평가하는 연구가 주를 이루었다. 단일 센서를 활용할 경우 영상에서 건물추출의 정확도는 더 높지만, 이중 센서로 촬영된 영상에 적용 시 건물탐지 정확도를 기대하기는 어려운 현실이다. 본 연구에서는 2018 R&D 과제에서 개발된 딥러닝(U-Net) 기법의 건물 객체 탐지 가능성을 확인하고, 건물탐지를 위해 웹에서 무료로 제공되는 데이터를 활용해 이중 센서로 촬영

된 영상에 대해 딥러닝 기반 건물탐지를 적용하고 이에 대한 활용 가능성을 분석하고자 한다.

2. 주요 내용

가. 연구추진 방법

본 연구는 2018 R&D 과제로 개발한 딥러닝 기반 건물 추출 알고리즘(Deep U-Net)과 최근 유사 선행연구에서 사용한 대표적인 건물 추출 알고리즘 분석한다. 건물탐지를 위한 최적의 딥러닝 적용 가능성을 분석하고, 이중 센서 영상에 대해 딥러닝 기반 건물탐지를 적용하는 것을 목표로 연구수행 절차는 그림 12-1과 같이 총 다섯 단계로 구성된다. R&D 과제 성과 분석 단계에서는 R&D 과제에서 수행된 딥러닝 기반 건물 추출에 대한 결과 분석을 수행한다. 이후 딥러닝 기반 건물 추출 알고리즘에 대한 선행연구결과를 분석 및 시범 적용할 알고리즘을 선정하고, 소량의 딥러닝 데이터 셋(Massachusetts Data set)을 구축하고 알고리즘 적용가능성을 평가하였다. 이후 이중 센서 영상에서의 딥러닝 기반 건물 객체 추출을 위해 웹을 통해 무료로 제공 중인 데이터 셋(Massachusetts Data set, Inria Data set)으로 딥러닝 데이터 셋을 구축 후 트레이닝을 진행하고, 최종적으로 건물탐지 결과를 적용하고 그 결과를 분석하였다.




<그림 10-1> 연구수행 절차

나. 연구 수행 내용

1) 2018 R&D 과제 성과분석

2018 R&D 과제는 건물과 도로를 대상으로 딥러닝 기반의 객체 추출 기술을 개발하였다. 해당 연구에서는 KOMPSAT-3A 영상을 활용하여 연구를 수행하였으며, 활용 가능한 영상의 부족으로 동일 영상 내에서 트레이닝 데이터 영상과 테스트 영상을 구성하였다. 트레이닝데이터 셋은 전체 영상에서 테스트 영상을 제외한 지역을 256×256픽셀(pixel)로 나누어 슬라이딩 윈도우(Sliding Window) 방식으로 구축하였으며, 딥러닝 알고리즘은 Deep U-Net을 사용하였다. 2018 R&D 과제에서 최종보고서에서 자체적으로 검증한 도로, 건물 추출한 결과 전체 분류 정확도는 90%이상

으로 높은 수준이었으며, 딥러닝으로 건물로 추출된 결과 중 실제 건물과 일치하는 비율을 의미하는 Precision은 74.9%로 나타났다. 2018 R&D 과제 결과로 제작된 객체추출 SW가 국토위성센터에 설치된 후 국토위성 촬영 영상을 가지고 건물객체를 추출한 결과 오탐지, 누락탐지 등이 많아 실제 R&D 연구과제 결과와 많은 차이가 있음을 알 수 있었다. 2018 R&D 과제에서 개발된 딥러닝 기반 객체 추출 기술 및 SW를 현업에 적용하기 위해서는 딥러닝 알고리즘의 개선, 다양한 트레이닝 데이터의 확보 및 다양한 지역에 대한 검증 등의 작업이 필요하다.



<그림 10-2> 국토위성 촬영영상 건물 추출 결과(37713017 도엽)

2) 선행연구 분석

본 연구의 목적은 R&D 과제를 통해 구현된 Deep U-Net 및 선행연구에서 건물탐지에 많이 활용된 알고리즘을 분석하고 딥러닝 알고리즘을 선정해 건물 추출을 시범 적용하는 것이다. 선행연구 파악을 위해 2015년부터 2021년까지 Taylor & Francis, IEEE, MDPI, ISPRS 등 원격탐사 관련 주요 학술지 딥러닝 기반 건물 추출 관련 연구를 검색했다. 검색 결과 딥러닝 기반의 건물 추출 관련 연구는 총 35편이었으며, 해당 논문에서 개발·적용한 알고리즘과 연구 성과의 비교를 위해 비교군으로 사용한 알고리즘에 대한 현황을 조사하였다. 연구에서 주요 분석 알고리즘과 비교군으로 사


용한 알고리즘은 <표2-1>과 같이 U-Net이 각각 11건(31%), 18건(24%)로 가장 많았으며, FCN, CNN, SegNet 알고리즘 순으로 활용되었다. CNN의 경우 주요 분석 및 비교 알고리즘으로 많이 사용(비교)되었으나 알고리즘 구조가 단순해 다양한 크기와 형태를 갖는 객체 추출에는 한계가 있다(Majd, Momeni, & Moallem, 2019). 따라서 건물탐지 연구에서는 R&D 과제에서 사용한 알고리즘인 U-Net과 FCN, SegNet 알고리즘을 활용해 건물 추출 가능성을 분석할 예정으로, 본 연구에서는 2018 R&D과제 성과물인 U-Net을 우선적으로 적용하여 건물 추출을 수행하고, FCN, SegNet 기반의 건물 추출은 향후 연구에서 수행하고 그 성능을 비교할 계획이다.

<표 10-1> 선행연구 적용 알고리즘 분석 결과

구분	주요분석 알고리즘	비교 알고리즘	합계
CNN	9	6	15
FCN	7	9	16
U-Net	11	18	29
SegNet	3	11	14
DeepLabv3+	0	10	10
기타	6	22	28

3) 딥러닝 알고리즘

CNN은 1989년 영상 필터링에 최초로 적용된 이후, 1998년 이후 영상 분류를 위해 활용된 알고리즘으로 Convolution, Subsampling(Pooling), Full Connection 3단계로 구성이 된다(LeCun, Bottou, Bengio, & Haffner, 1998).




<그림 10-3> CNN 알고리즘 구조

Convolution은 영상에서 특징점 추출을 위해 필터를 통해 압축하는 과정을 의미하며, Pooling 과정은 연산속도를 줄이고, 영상 내 객체에 특징점 강조의 역할을 한다. Convolution과 Pooling 과정을 반복하면 최종 Full-Connection 단계에 도달하게 되는데, 이 단계는 영상의 객체를 분류하는 단계로, 입력 영상(Input Image)을 Convolution과 Pooling 과정을 반복해 1차원으로 변환된 벡터를 하나의 레이어로 연결해 영상에서 객체를 분류하게 된다. CNN은 Full-Connection에서 각 1차원 벡터가 하나의 레이어로 합쳐짐에 따라, 이미지의 공간정보가 상실되는 단점이 있다.

CNN의 Convolution, Pooling 과정의 반복 이후, 영상 내 객체의 공간정보가 상실되는 한계를 보완하기 위해 2015년 FCN 알고리즘이 제안 되었다. FCN은 Convolution, Pooling 단계는 CNN과 동일하고, 이후 과정에 Upsampling이 추가된 형태로 이 단계에서는 Pooling 과정에의 정보를 활용해 영상의 Sematic Segmentation 정보를 추출하게 된다(Long, Shelhamer, & Darrell, 2015). Pooling layer 개수의 활용에 따라, FCN-32S, FCN-16S, FCN-8S로 구분된다.

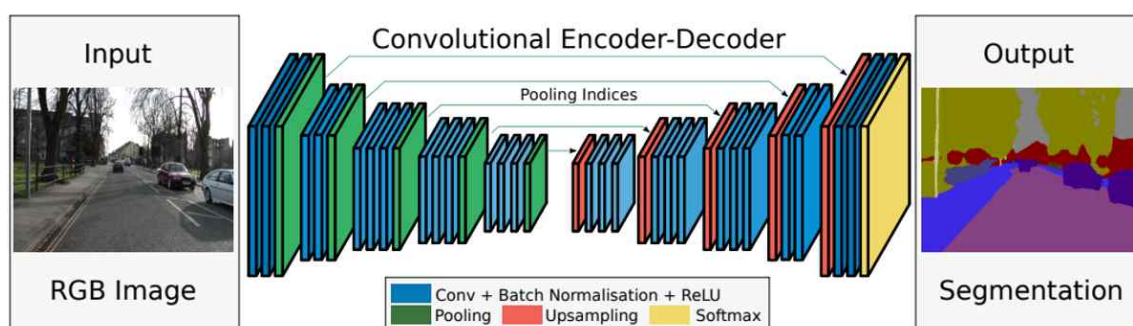
U-Net은 FCN과 유사한 과정으로 FCN의 Upsampling 과정에서 발생하는 정보의 손실을 최소화하기 위해, Convolution 과정에서의 특징점에 대한 정보를 Copy and Crop하여 복원 시 영상 손실을 최소화 하는 방식이다. U-Net은 의료분야 활용을 위해 처음 제안되었으며 위성, 항공영상에서는 건물 등 비교적 작은 객체 탐지-추출에 장점이 있다.(Ronneberger, Fischer, & T. Brox, 2015).



<그림 10-4> FCN(좌), U-Net(우) 알고리즘 구조

SegNet은 도로, 빌딩, 차량 등에 대한 정보의 추출을 위해 고안된 알고리즘으로, 그림 12-5와

같이 5단계의 Convolution, Pooling을 수행하는 Encoder와 5단계의 Upconvolution, Upsampling 과정의 Decoder로 구성되어 있으며 Encoder, Decoder 각각 13번의 Convolution 과정을 거치게 된다. SegNet은 Encoder 과정에서 Max-Pooling의 정보를 Upsampling 과정에서 활용함에 따라 특정 객체의 분류 결과와 입력 영상과 동일한 크기로 표현되는 장점이 있다(Badrinarayanan, Kendall, & Cipolla, 2017).



<그림 10-5> SegNet 알고리즘 구조

4) 파이썬 통합개발환경(IDE)

통합개발환경(IDE)은 Integrated Development Environment의 약자로, 특정한 개발환경 안에서 코드를 작성하고 작성된 코드가 해당 프로그래밍 언어의 문법에 맞는지 확인할 수 있을 뿐만 아니라 잘못된 부분을 수정하고 실행결과까지 미리 확인할 수 있다. 파이썬도 다양한 통합개발환경을 이용할 수 있으며, 약 2,500명을 대상으로 2018년 2020년 가장 많이 사용하는 파이썬 통합개발환경을 조사한 결과 Jupyter, Visual Studio Code, Pycharm 등이 많이 사용하는 것으로 나타났다(KDnuggets, 2021.09.07.)

Jupyter는 웹 기반의 통합개발환경으로 코드를 블록 단위로 쪼개서 작성, 실행하고 그 결과를 바로바로 확인할 수 있는 장점이 있으며, 시각화 라이브러리를 이용해 표와 그래프를 즉시 확인 가능하다는 장점이 있다. 하지만 디버깅 기능이 없고 웹 기반이므로 항상 모든 코드를 처음부터 실행해야 하는 단점이 있다. 또한 'ipybn'라는 Jupyter 전용 확장자를 사용해서 다른 IDE에서는 사용하기가 어려운 단점이 있다.

Visual Studio Code(VS Code)는 마이크로소프트에서 만든 코드편집기로 완성도가 가장 높은 IDE 중에 하나이다. 많은 기능을 가지고 있지만 가볍다는 장점이 있으며, 오픈소스이므로 무료로

사용할 수 있다. 또한 확장 프로그램을 통해 C, C#, Java Script 등 다양한 언어 코딩이 가능하고, 한국어 패치가 가능하다. 반면, Pycharm 등과 같이 파이썬 전용 IDE 대비 세부적인 기능이 부족하다는 단점이 있다.

Pycharm은 파이썬 IDE 중에 가장 유명한 것으로, 파이썬만을 위해 개발되었다. Pycharm은 프로젝트별로 파이썬 버전을 선택할 수 있는 장점이 있으며, GUI로 편리하게 라이브러리(패키지)를 설치할 수 있는 장점이 있다. 그러나 파이썬 전용으로만 사용되는 IDE로 타 언어와 호환 절차가 복잡하고, 프로그램이 무거운 단점이 있다.

5) U-Net 알고리즘 구현 및 검증

가) 시스템 환경설정

본 연구에서는 파이썬 가상환경 등을 쉽게 만들 수 있는 아나콘다(anaconda)를 활용하였다. 파이썬은 3.8 버전을 사용하였으며, 통합개발환경은 Pycharm을 사용하였다. 또한, 딥러닝 수행을 위해 Pytorch, Tensorflow 가상환경을 구축하였고, 데이터 트레이닝 및 건물 탐지는 Google Colab Pro를 활용하였다.

나) 딥러닝 데이터셋(트레이닝, 검증, 테스트) 구축

이종 센서 데이터의 딥러닝 성능 확인 전 U-Net 알고리즘의 건물탐지 가능성을 확인하고자, 웹에서 무료로 제공되는 데이터 중 일부를 샘플링(Sampling)하여 딥러닝 데이터 셋을 구축하였다. 현재 웹에서 무료로 제공 중인 건물탐지를 위한 데이터는 ISPRS Data set, Massachusetts Data set, Inria Data set, WHU Aerial Dataset 등이 있다. 이 중 공간해상도 1m인 Massachusetts Data set을 활용하여 U-Net의 건물탐지 가능성을 우선 확인하였다. Massachusetts Data set은 Massachusetts지역 도로, 건물 객체의 Labeling 영상 생성을 위한 연구에 사용된 데이터이다 (Mnih, 2013). 해당 데이터 셋은 건물 151장(1,500×1,500 픽셀)의 항공영상과 Labeling 영상을 제공하고 있다. 본 연구에서는 151장의 Massachusetts Data set 중 60장의 영상을 트레이닝 48장, 검증 6장, 테스트 6장으로 분류해서 U-Net 검증을 위한 데이터로 활용하였다. 또한, 하드웨어의 성능을 고려하여, 60장의 영상을 512×512 픽셀로 분할하여 트레이닝용 데이터 192개, 검증용 데이터 24개, 테스트용 데이터 24개를 각각 랜덤하게 생성하였다. 또한 생성된 데이터는 트레이닝 과정에서 분석이 가능하도록 Tensor 형태로 변환 후 상하/좌우 반전을 랜덤하게 입력되


도록 부록 1과 같이 데이터를 처리하였다.



<그림 10-6> Massachusetts Data Set(좌 : 원영상, 우 : Label / 1,500×1,500픽셀)

다) U-Net 알고리즘 구현

Ronneberger 등(2015)에서 제시한 U-Net 구조는 크게 Contraction path와 Expansive path로 구분된다. Contracting path의 각 단계에서는 두 번의 3×3 합성곱(Convolution)과 ReLU, 2×2 max pooling 과정을 갖게 된다. 이러한 과정을 총 5회를 반복하며, 각 단계를 가치면서 영상의 사이즈는 절반으로 줄어들게 되고, feature의 채널 수는 2배로 증가하게 된다. Expansive path는 Contracting path 작업의 역순으로 각 단계에서 2×2 up-convolution 이후 두 번의 3×3 합성곱과 ReLU를 반복 하는 작업을 진행하였다, 또한 up-convolution 직후 Contracting path에서 생성된 feature를 crop & copy해서 합쳐주는 과정을 통해 객체의 위치 정보를 반영할 수 있다. 본 연구에서는 U-Net 합성곱 구현 시 Stride와 padding 값을 각각 1로 설정(기존 U-Net은 Stride, Padding을 각각 0으로 설정, Ronneberger 등(2015))하여 Contracting path와 Expansive path에서 영상 사이즈가 일치하도록 하였다. 영상 사이즈가 동일할 경우 Expansive path에서 Contracting path feature를 crop & copy 할 때, crop의 과정을 생략하고, copy과정만을 통해 feature 정보를 불러올 수 있는 장점이 있다. 본 실험에 사용되는 영상(512×512 픽셀)을 반영하여 U-Net의 알고리즘을 그림 12-7과 같이 구현하였다(Python code 부록 2).




<그림 10-7> U-Net 알고리즘 구조(512×512픽셀 영상, stride=1, padding=1)

라) 네트워크 트레이닝 및 U-Net 알고리즘 성능 검증

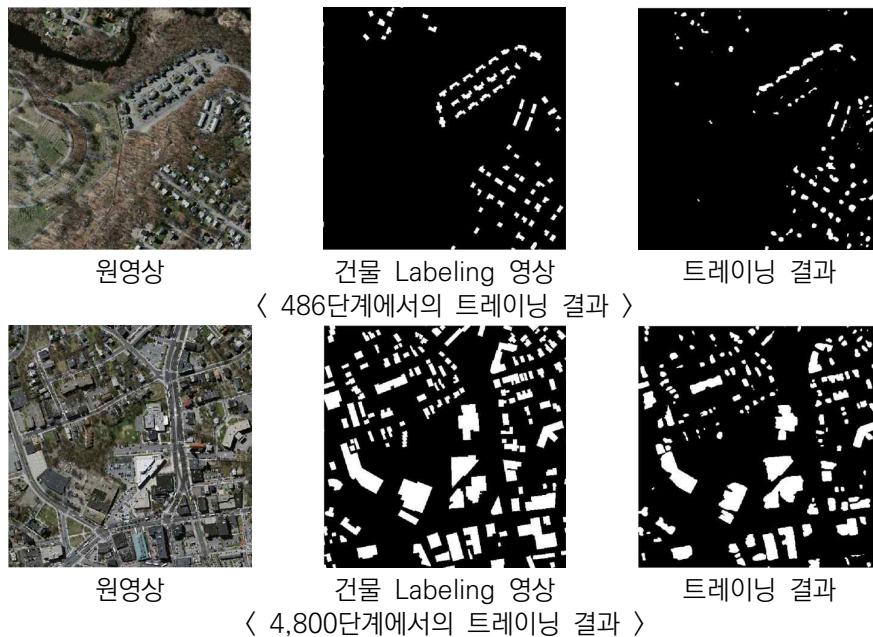
Python으로 구현한 네트워크 트레이닝은 Google Colab Pro를 이용하여 진행했다. 트레이닝을 위한 주요 변수는 데이터와 Colab의 가용 가능 사양을 고려하여 Learning rate는 0.001, Batch Size는 4, Epoch는 100회로 정의하였다. 손실함수는 BCE(Binary Cross Entropy)를 사용하였고, Optimizer는 Adam을 사용했다. 이러한 변수를 바탕으로 최종 트레이닝 진행을 위한 네트워크를 저장하고 불러오는 함수를 <부록 3>처럼 구현하였고, 최종 딥러닝 데이터셋 적용을 위한 U-Net Python code는 <부록 4>와 같이 구현하였다.

트레이닝 총 192장을 4개의 Batch Size로 묶어 100회 Epoch를 수행한 결과 총 4,800단계(Step)의 트레이닝이 수행되었고, 검증은 24장을 4개의 Batch size로 묶어 100회 Epoch를 수행한 결과 600단계(Step)의 검증이 수행되었다. 그림 12-8은 트레이닝 및 검증의 결과로 최종 단계에서 트레이닝, 검증 손실함수 모두 0.12수준으로 나타났다. 손실함수는 딥러닝을 통해 나오는 결과값과 실제 건물과(건물 Labeling 영상)의 오차를 의미하는 것으로 손실함수 값이 작을수록 실제 영상과의 오차가 적은 것을 의미하며, 트레이닝을 반복하며 Optimizer를 통해 손실함수를 최소화 할 수 있는 가중치(weight)와 편향(bias)을 찾게 된다.



<그림 10-8> U-Net 트레이닝 및 검증 결과

단계별로 보면 초기 486 단계(11epoch 2번째 batch)에서는 건물의 오탐지, 누락 탐지가 발생하고 건물의 형태가 잘 추출되지 않을 것을 볼 수 있다. 하지만 최종 4,800단계(100epoch, 48번째 batch)에서는 오탐지, 누락탐지가 많이 줄어들고 건물의 형태도 어느 정도 추출된 것을 확인할 수 있었다.



<그림 10-9> U-Net 트레이닝 결과 비교

또한, U-Net의 건물탐지 가능성을 확인하기 위해 트레이닝 및 검증에 활용되지 않은 영상 24장을 활용하여 테스트를 수행한 결과 손실함수의 최대값은 0.0829, 최소값은 0.0220으로 U-Net의 건물 탐지 가능성을 확인하였다.

6) 이종 센서 영상에서의 건물탐지 수행 및 결과 분석

가) 이종 센서 영상의 딥러닝 데이터 셋(트레이닝, 검증, 테스트) 구축

U-Net의 건물탐지 가능성을 확인 후 다양한 센서로부터 취득된 영상을 트레이닝 데이터로 활용하여 건물 탐지를 수행하였다. 트레이닝 데이터는 10cm 미만의 해상도가 아주 높은 영상을 제외하고, Massachusetts Data set(해상도 1m), Inria Data set(해상도 0.3m), WHU Aerial Dataset(해상도 0.3m) 세 가지를 사용할 계획이었으나, WHU Aerial Dataset가 다운로드가 불가하여, Massachusetts, Inria Data set을 활용하였다. Inria Data set은 다양한 도시에서 촬영한 데이터를 제공하고 있어, 본 연구에서는 Texas주의 Austin과 Illinois 주의 Chicago를 트레이닝 데이터로 활용하였다.

U-Net 적용을 위한 데이터는 3개의 도시를 모두 균등하게 구성하기 위해 Massachusetts Data set은 총 89장의 영상($1,500 \times 1,500$ 픽셀)을 랜덤하게 추출하였으며, Inria Data set에서는 각 지역별로 8장($5,000 \times 5,000$ 픽셀)을 랜덤하게 추출하여 512×512 픽셀의 영상으로 분할하여 총 972장의 트레이닝 영상(각 지역별 324장), 72장의 검증 영상(각 지역별 24장), 24장의 테스트 영상(각 지역별 8장)으로 구성하였다.



Massachusetts Data Set

Inria Data Set(Austin)

Inria Data Set(Chicago)

<그림 10-10> U-Net 기반 건물탐지를 위한 데이터 구축

나) 네트워크 트레이닝 및 건물추출 결과

네트워크 트레이닝 시 주요 변수는 U-Net 알고리즘 검증 단계와 동일하게 Learning rate는 0.001, Batch Size는 4, Epoch는 100회, 손실함수는 BCE(Binary Cross Entropy), Optimizer는 Adam을 사용했다. 총 972개의 데이터를 4개의 batch size로 묶어 100회 Epoch를 수행해 총 24,300단계의 트레이닝을 수행하였고, 검증을 위해 총 72개의 데이터를 4개의 batch size로 묶어 1,800단계의 검증을 수행한 결과 트레이닝 결과의 손실함수 값은 0.11, 검증데이터의 손실함수 값은 0.14수준으로 분석되었다.



<그림 10-11> 이중 센서 영상의 U-Net 트레이닝 및 검증 결과

트레이닝 결과를 바탕으로 테스트 데이터 24개를 테스트한 결과 손실함수는 0.13~0.16범위로 나타났으며, 각 지역별 탐지 결과는 그림 12-12와 같다. 전체적으로 일부 누락은 있었지만 대부분의 건물을 잘 탐지하고 있음을 확인할 수 있었다. 다만 1m 해상도인 Massachusetts Data의 경우, 0.3m 영상인 Inria data에 비해 상대적으로 건물 엣지(edge)등에 대한 탐지가 많이 누락된 것을 확인할 수 있었다. 이는 상대적으로 해상도 낮은 영상의 경우 건물 엣지 부근에서 픽셀 내에 건물 외에 식생, 도로 등 다양한 지표 정보가 혼용될 가능성이 높아 건물 중앙 부분과의 화소값과 차이가 발생해 누락이 발생한 것으로 판단된다.

다) 정확도 분석

본 연구에서의 건물탐지 결과의 정확도는 선행연구에서 주로 활용한 Precision, Recall, IoU(Intersection over Union)을 활용하여 분석하였다. Recall의 경우 실제 건물(Label) 중에 실험결과에서 탐지된 건물(Output)과 일치하는 비율을 의미하며, Precision은 건물 탐지 결과 중 실제 건물과 일치하는 비율을 의미한다. IoU의 경우 실제 건물과 실험을 통해 탐지한 건물의 중첩되는 면적이 실제 건물과 탐지 건물 면적의 합에서 차지하는 비율을 의미한다.



원영상




건물 Labeling 영상



건물 탐지 결과

Massachusetts Data Set(22679005_15)



원영상



건물 Labeling 영상



건물 탐지 결과

Inria Data Set(Austin 28)



원영상



건물 Labeling 영상



건물 탐지 결과

Inria Data Set(Chicago 4)

<그림 10-12> 각 Data 별 건물탐지 결과

전체 24장의 테스트 데이터 정확도 분석 결과, 표12-2와 같이 Recall은 0.767, Precision 0.868, IoU는 0.687로 나타났다. 세부적으로 Inria Data set의 Austin 지역이 Recall 0.859, Precision 0.916, IoU 0.797로 가장 높게 나타났다. 전체적으로 Recall이 Precision보다 낮게 나타났으며, 이를 통해 오탐지 보다는 누락탐지가 많았음을 알 수 있다. Massachusetts의 경우 상대적으로 고해상도 영상인 Inria Data set보다 정확도가 모두 낮았으며, 이는 앞서 언급한 건물 엣지 등에서의 DN Range의 영향 등으로 인한 누락이 되었음을 추측할 수 있다.

또한, Inria Data Set의 Austin의 경우 전체적으로 같은 Data set의 Chicago 보다 정확도가 더 높았음을 확인할 수 있다. 실제 촬영영상을 확인한 결과 Chicago 지역은 상대적으로 Austin 지역보다 높은 건물이 많았고, 높은건물의 건물의 정확한 경계 추출의 어려움과 그림자 등으로 인한 오탐지가 상대적으로 많이 발생한 것으로 판단된다.

<표 10-2> 정확도 평가 결과

구분	Total	Massachusetts	Inria	
			Austin	Chicago
Recall	0.767	0.607	0.859	0.878
Precision	0.868	0.850	0.916	0.827
IoU	0.687	0.548	0.797	0.673

본 연구의 건물탐지 결과 정확도의 객관적인 분석을 위해 U-Net 기반의 건물탐지 선행연구의 결과들과 비교하였다(표12-3). 선행 연구중 가장 좋은 결과를 보인 Ji 등(2018)이 제안한 SiUNet은 Recall 0.939, Precision 0.938, IoU는 0.884를 보였다. 본 연구의 결과는 선행연구의 정확도보다 다소 낮은 수준이었으나, 본 연구가 타 선행연구와 달리 U-Net을 개선하지 않고 이중 센서 데이터를 기반으로 딥러닝 기반 건물탐지를 적용할 수 있는 가능성을 확인하는데 그 의의가 있다고 판단된다. 실제로 본 실험에서 고해상도인 Inria Data set만 별도로 그 정확도를 계산해 보면 Recall은 0.869, Precision은 0.872, IoU는 0.735로 이는 Liu 등(2021)이 제안한 PRU-Net의 정확도와 큰 차이가 없음을 확인할 수 있다.

<표 10-3> 유사 연구와 정확도 평가 결과 비교

구분	본 연구결과	SiU-Net (Ji 등(2018))	PRU-Net (Liu 등(2021))	AMUNET (Guo 등(2020))	RFA-UNet (Ye 등(2019))
Recall	0.767	0.939	0.952	-	-
Precision	0.868	0.938	0.857	-	-

IoU	0.687	0.884	0.698	0.843	0.900
-----	-------	-------	-------	-------	-------

라) 이중 센서의 건물탐지 영향 분석

본 연구의 주요 목적 중 하나는 이중 센서 데이터를 활용한 딥러닝 기반 건물탐지 가능성을 확인하는 것으로, 실제 이중 센서가 건물 탐지에서 어느정도 영향을 미치는지 파악하기 위해 단일 센서 영상만을 활용하여 딥러닝 기반의 건물 추출 결과와의 차이를 확인할 필요가 있다. 따라서 본 실험에서 활용한 Data Set 중 Inria Data Set을 제외하고 Massachusetts Data Set 만을 활용해서 학습하고 그 결과를 이중센서 데이터를 활용한 건물추출 결과와 비교하였다. 추가적인 Massachusetts Data Set은 이중 센서와 구성한 Massachusetts Data Set과 동일하게 트레이닝 데이터는 324장, 검증 24장, 테스트 8장으로 동일하게 맞춰주었으며, 학습 및 건물 탐지를 위한 주요 변수도 동일하게 유지하였다.

정확도 분석결과 Massachusetts Data Set 지역만을 사용하여 건물을 추출한 경우에 Recall, IoU가 높아진 것을 확인할 수 있었고, Precision은 다소 낮아졌음을 확인하였다(표 12-4). Recall, IoU 등이 증가하는 것으로 보아 단일 센서 영상을 활용할 경우 실제 건물 탐지가 좋아지는 것을 확인할 수 있었다. 그러나 한편으로 단일 센서 영상에서 Precision은 오히려 감소한 것으로 볼 때 단일 센서에서 실제 건물에 대한 탐지도 증가함과 동시에, 오탐지 확률도 증가하는 것을 알 수 있다. 향후 다양한 이중 센서 데이터를 추가적으로 활용할 경우 정확도가 더 낮아질 것을 대비하여 이를 고려한 딥러닝 알고리즘 개선, 학습량 증가 등의 대안이 필요할 것으로 판단된다.

<표 10-4> 이중센서 및 단일센서 데이터의 건물 추출 정확도 분석 결과

구분	Massachusetts 지역 (Massachusetts & Inria, training 927장)	Massachusetts (Massachusetts 327장)
Recall	0.607	0.736
Precision	0.850	0.845
IoU	0.548	0.649

3. 결론

본 연구는 최근 컴퓨팅 성능 개선 및 다양한 딥러닝 알고리즘의 개발로 인해 많이 활용되고 있는 딥러닝 기술을 활용하여 고해상도 영상으로부터 건물 추출 가능성을 확인하고자 하였다. 본 연구에서는 건물탐지로 많이 활용되는 U-Net을 직접 구현하여 건물탐지 가능성 확인하고, 이중센서 영상을 활용한 U-Net 기반 건물 탐지 가능성 확인하는 등 크게 두 가지를 목표로 하였다. 웹에서 무

료로 제공 중인 Massachusetts Data Set을 활용하여 실제 U-Net을 구현하고 테스트를 수행하여 U-Net의 건물탐지 가능성을 확인하였다. 이와 더불어 Massachusetts Data Set, Inria Data Set 등 2개의 서로 다른 센서 데이터에서 3개 지역을 추출하여 이중 센서의 건물 탐지를 수행한 결과, Recall 0.767, Precision 0.868, IoU 0.687의 정확도로 건물 추출 가능성을 확인하였다. 본 연구는 단일센서를 통해 영상을 취득한 기존연구들과 달리 이중센서로부터 취득한 영상에서의 건물추출 가능성을 확인한데 그 의의가 있다.

그러나 본 연구에서는 유사한 연구들이 U-Net을 기반으로 알고리즘을 개선한 것과 달리 U-Net 알고리즘만을 적용하여 선행연구들에 비해 정확도가 다소 낮은 한계점이 있다. 또한 제한된 컴퓨팅 성능으로 인해 유사 연구보다 딥러닝 데이터 셋을 적게 구성하였으며, Batch Size도 더 작게 설정하였다. 향후 연구에서는 U-Net 기반의 건물탐지 정확도 향상을 위해 알고리즘의 개선과 학습데이터의 양과 횟수 등의 증가가 필요하다.

본 연구에서는 이중 데이터셋의 건물탐지 가능성을 확인하였으나, 두 개의 센서에서 취득된 자료로 실험을 수행하였다는 한계가 있다. 향후 연구에는 다양한 센서에서 취득된 자료를 활용한 추가적인 실험이 필요하다. 본 연구에서 1m 해상도의 Massachusetts Data Set의 정확도가 0.3m Inria Data Set 보다 낮은 것을 고려할 때 향후 연구에서는 이중 센서 데이터 구축 시 1m 미만의 고해상도 영상을 활용하여 데이터를 구축할 예정이다.

또한 현재 구현한 U-Net 외에 현재 FCN, SegNet 등 딥러닝 알고리즘에 대해서도 동일하게 건물 탐지 가능성에 대한 실험을 수행할 예정이다. 향후 궁극적으로는 국토위성에 적용·활용 할 수 있도록 국토위성 영상을 활용한 실험도 추진할 계획이다.

부록

부록 1. 데이터 로드

```
import os
import numpy as np
import torch
import torch.nn as nn

## 데이터 로더
class Dataset(torch.utils.data.Dataset):
    def __init__(self, data_dir, transform=None):
        self.data_dir = data_dir
        self.transform = transform
        lst_data = os.listdir(self.data_dir)
        lst_label = [f for f in lst_data if f.startswith('label')]
        lst_input = [f for f in lst_data if f.startswith('input')]
        lst_label.sort()
        lst_input.sort()
        self.lst_label = lst_label
        self.lst_input = lst_input

    def __len__(self):
        return len(self.lst_label)

    def __getitem__(self, index):
        label = np.load(os.path.join(self.data_dir, self.lst_label[index]))
        input = np.load(os.path.join(self.data_dir, self.lst_input[index]))
        label = label/255.0
        input = input/255.0
        if label.ndim == 2:
            label = label[:, :, np.newaxis]
        if input.ndim == 2:
            input = input[:, :, np.newaxis]
        data = {'input': input, 'label': label}
        if self.transform:
            data = self.transform(data)
        return data

## 데이터 트랜스폼
```

```

class ToTensor(object):
    def __call__(self, data):
        label, input = data['label'], data['input']
        label = label.transpose((2, 0, 1)).astype(np.float32)
        input = input.transpose((2, 0, 1)).astype(np.float32)
        data = {'label': torch.from_numpy(label), 'input': torch.from_numpy(input)}
        return data

class Normalization(object):
    def __init__(self, mean=0.5, std=0.5):
        self.mean = mean
        self.std = std

    def __call__(self, data):
        label, input = data['label'], data['input']
        input = (input - self.mean) / self.std
        data = {'label': label, 'input': input}
        return data

class RandomFlip(object):
    def __call__(self, data):
        label, input = data['label'], data['input']
        if np.random.rand() > 0.5:
            label = np.fliplr(label)
            input = np.fliplr(input)
        if np.random.rand() > 0.5:
            label = np.flipud(label)
            input = np.flipud(input)
        data = {'label': label, 'input': input}
        return data

```

부록 2. U-Net 구조 구현

```

import os
import numpy as np
import torch
import torch.nn as nn
import torch.nn.functional as F

## 네트워크 구축
class UNet(nn.Module):
    def __init__(self):

```

```

super(UNet, self).__init__()
def CBR2d(in_channels, out_channels, kernel_size=3, stride=1, padding=1,
        bias=True):
    layers = []
    layers += [nn.Conv2d(in_channels=in_channels, out_channels=out_channels,
                        kernel_size=kernel_size, stride=stride, padding=padding,
                        bias=bias)]
    layers += [nn.BatchNorm2d(num_features=out_channels)]
    layers += [nn.ReLU()]
    cbr = nn.Sequential(*layers)
    return cbr

# Contracting path
self.enc1_1 = CBR2d(in_channels=3, out_channels=64)
self.enc1_2 = CBR2d(in_channels=64, out_channels=64)
self.pool1 = nn.MaxPool2d(kernel_size=2)

self.enc2_1 = CBR2d(in_channels=64, out_channels=128)
self.enc2_2 = CBR2d(in_channels=128, out_channels=128)
self.pool2 = nn.MaxPool2d(kernel_size=2)

self.enc3_1 = CBR2d(in_channels=128, out_channels=256)
self.enc3_2 = CBR2d(in_channels=256, out_channels=256)
self.pool3 = nn.MaxPool2d(kernel_size=2)

self.enc4_1 = CBR2d(in_channels=256, out_channels=512)
self.enc4_2 = CBR2d(in_channels=512, out_channels=512)
self.pool4 = nn.MaxPool2d(kernel_size=2)
self.enc5_1 = CBR2d(in_channels=512, out_channels=1024)

# Expansive path
self.dec5_1 = CBR2d(in_channels=1024, out_channels=512)

self.unpool4 = nn.ConvTranspose2d(in_channels=512, out_channels=512,
                                kernel_size=2, stride=2, padding=0, bias=True)
self.dec4_2 = CBR2d(in_channels=2 * 512, out_channels=512)
self.dec4_1 = CBR2d(in_channels=512, out_channels=256)

self.unpool3 = nn.ConvTranspose2d(in_channels=256, out_channels=256,
                                kernel_size=2, stride=2, padding=0, bias=True)
self.dec3_2 = CBR2d(in_channels=2 * 256, out_channels=256)
self.dec3_1 = CBR2d(in_channels=256, out_channels=128)

self.unpool2 = nn.ConvTranspose2d(in_channels=128, out_channels=128,
                                kernel_size=2, stride=2, padding=0, bias=True)

```

```

self.dec2_2 = CBR2d(in_channels=2 * 128, out_channels=128)
self.dec2_1 = CBR2d(in_channels=128, out_channels=64)

self.unpool1 = nn.ConvTranspose2d(in_channels=64, out_channels=64,
                                   kernel_size=2, stride=2, padding=0, bias=True)
self.dec1_2 = CBR2d(in_channels=2 * 64, out_channels=64)
self.dec1_1 = CBR2d(in_channels=64, out_channels=64)

self.fc = nn.Conv2d(in_channels=64, out_channels=1, kernel_size=1,
                    stride=1, padding=0, bias=True)

def forward(self, x):
    enc1_1 = self.enc1_1(x)
    enc1_2 = self.enc1_2(enc1_1)
    pool1 = self.pool1(enc1_2)

    enc2_1 = self.enc2_1(pool1)
    enc2_2 = self.enc2_2(enc2_1)
    pool2 = self.pool2(enc2_2)

    enc3_1 = self.enc3_1(pool2)
    enc3_2 = self.enc3_2(enc3_1)
    pool3 = self.pool3(enc3_2)

    enc4_1 = self.enc4_1(pool3)
    enc4_2 = self.enc4_2(enc4_1)
    pool4 = self.pool4(enc4_2)

    enc5_1 = self.enc5_1(pool4)

    dec5_1 = self.dec5_1(enc5_1)

    unpool4 = self.unpool4(dec5_1)
    diffY = unpool4.size()[2] - enc4_2.size()[2]
    diffX = unpool4.size()[3] - enc4_2.size()[3]
    enc4_2 = F.pad(enc4_2, [diffX // 2, diffX - diffX // 2, diffY // 2, diffY - diffY // 2])
    cat4 = torch.cat((unpool4, enc4_2), dim=1)
    dec4_2 = self.dec4_2(cat4)
    dec4_1 = self.dec4_1(dec4_2)

    unpool3 = self.unpool3(dec4_1)
    diffY = unpool3.size()[2] - enc3_2.size()[2]
    diffX = unpool3.size()[3] - enc3_2.size()[3]
    enc3_2 = F.pad(enc3_2, [diffX // 2, diffX - diffX // 2, diffY // 2, diffY - diffY // 2])
    cat3 = torch.cat((unpool3, enc3_2), dim=1)

```

```

dec3_2 = self.dec3_2(cat3)
dec3_1 = self.dec3_1(dec3_2)

unpool2 = self.unpool2(dec3_1)
diffY = unpool2.size()[2] - enc2_2.size()[2]
diffX = unpool2.size()[3] - enc2_2.size()[2]
enc2_2 = F.pad(enc2_2, [diffX // 2, diffX - diffX // 2, diffY // 2, diffY - diffY // 2])
cat2 = torch.cat((unpool2, enc2_2), dim=1)
dec2_2 = self.dec2_2(cat2)
dec2_1 = self.dec2_1(dec2_2)

unpool1 = self.unpool1(dec2_1)
diffY = unpool1.size()[2] - enc1_2.size()[2]
diffX = unpool1.size()[3] - enc1_2.size()[2]
enc1_2 = F.pad(enc1_2, [diffX // 2, diffX - diffX // 2, diffY // 2, diffY - diffY // 2])
cat1 = torch.cat((unpool1, enc1_2), dim=1)
dec1_2 = self.dec1_2(cat1)
dec1_1 = self.dec1_1(dec1_2)

x = self.fc(dec1_1)
return x

```

부록 3. 네트워크 저장 및 불러오기

```

import os
import numpy as np
import torch
import torch.nn as nn

## 네트워크 저장하기
def save(ckpt_dir, net, optim, epoch):
    if not os.path.exists(ckpt_dir):
        os.makedirs(ckpt_dir)
    torch.save({'net': net.state_dict(), 'optim': optim.state_dict()},
               "%s/model_epoch%d.pth" % (ckpt_dir, epoch))

## 네트워크 불러오기
def load(ckpt_dir, net, optim):
    if not os.path.exists(ckpt_dir):
        epoch = 0
        return net, optim, epoch
    ckpt_lst = os.listdir(ckpt_dir)

```

```

ckpt_lst.sort(key=lambda f: int(''.join(filter(str.isdigit, f))))
dict_model = torch.load('%s/%s' % (ckpt_dir, ckpt_lst[-1]))
net.load_state_dict(dict_model['net'])
optim.load_state_dict(dict_model['optim'])
epoch = int(ckpt_lst[-1].split('epoch')[1].split('.pth')[0])

return net, optim, epoch

```

부록 4. U-Net 트레이닝, 검증, 테스트 알고리즘 구현

```

##라이브러리 추가하기
import argparse
import os
import numpy as np
import torch
import torch.nn as nn
from torch.utils.data import DataLoader
from torch.utils.tensorboard import SummaryWriter
from model import UNet
from dataset import *
from util import *
import torch.nn.functional as F
import matplotlib.pyplot as plt
from torchvision import transforms, datasets

## Parser 설정하기
parser = argparse.ArgumentParser(description="Train the UNet",
                                formatter_class=argparse.ArgumentDefaultsHelpFormatter)
parser.add_argument("--lr", default=1e-3, type=float, dest="lr")
parser.add_argument("--batch_size", default=4, type=int, dest="batch_size")
parser.add_argument("--num_epoch", default=100, type=int, dest="num_epoch")
parser.add_argument("--data_dir", default="./datasets", type=str, dest="data_dir")
parser.add_argument("--ckpt_dir", default="./checkpoint", type=str, dest="ckpt_dir")
parser.add_argument("--log_dir", default="./log", type=str, dest="log_dir")
parser.add_argument("--result_dir", default="./results", dest="result_dir")
parser.add_argument("--mode", default="train", type=str, dest='mode')
parser.add_argument("--train_continue", default="off", type=str, dest="train_continue")
args = parser.parse_args()
## 트레이닝 파라미터 설정하기
lr = args.lr
batch_size = args.batch_size
num_epoch = args.num_epoch

```

```

data_dir = args.data_dir
ckpt_dir = args.ckpt_dir
log_dir = args.log_dir
result_dir = args.result_dir
mode = args.mode
train_continue = args.train_continue
device = torch.device('cuda' if torch.cuda.is_available() else 'cpu')

## 디렉토리 생성하기
if not os.path.exists(result_dir):
    os.makedirs(os.path.join(result_dir, 'png'))
    os.makedirs(os.path.join(result_dir, 'numpy'))

## 네트워크 학습하기
if mode == 'train':
    transform = transforms.Compose([Normalization(mean=0.5, std=0.5), RandomFlip(), ToTensor()])

    dataset_train = Dataset(data_dir=os.path.join(data_dir, 'train'), transform=transform)
    loader_train = DataLoader(dataset_train, batch_size=batch_size, shuffle=True, num_workers=2)
    dataset_val = Dataset(data_dir=os.path.join(data_dir, 'val'), transform=transform)
    loader_val = DataLoader(dataset_val, batch_size=batch_size, shuffle=False, num_workers=2)

    ## 부수적인 variable 설정하기
    num_data_train = len(dataset_train)
    num_data_val = len(dataset_val)
    num_batch_train = np.ceil(num_data_train / batch_size)
    num_batch_val = np.ceil(num_data_val / batch_size)

else:
    ## 네트워크 학습하기
    transform = transforms.Compose([Normalization(mean=0.5, std=0.5), ToTensor()])
    dataset_test = Dataset(data_dir=os.path.join(data_dir, 'test'), transform=transform)
    loader_test = DataLoader(dataset_test, batch_size=batch_size, shuffle=False, num_workers=2)
    ## 부수적인 variable 설정하기
    num_data_test = len(dataset_test)
    num_batch_test = np.ceil(num_data_test / batch_size)

## 네트워크 생성하기
net = UNet().to(device)

## 손실함수 정의하기
fn_loss = nn.BCEWithLogitsLoss().to(device)

##Optimizer 설정하기
optim = torch.optim.Adam(net.parameters(), lr=lr)

```



```

## 부수적인 functions 설정하기
fn_tonumpy = lambda x: x.to('cpu').detach().numpy().transpose(0, 2, 3, 1)
fn_denorm = lambda x, mean, std: (x * std) + mean
fn_class = lambda x: 1.0 * (x > 0.5)

## Tensorboard를 사용하기 위한 SummaryWriter 설정
writer_train = SummaryWriter(log_dir=os.path.join(log_dir, 'train'))
writer_val = SummaryWriter(log_dir=os.path.join(log_dir, 'val'))

## 네트워크 학습시키기
st_epoch = 0

# TRAIN MODE
if mode == 'train':
    if train_continue == "on":
        net, optim, st_epoch = load(ckpt_dir=ckpt_dir, net=net, optim=optim)
    for epoch in range(st_epoch + 1, num_epoch + 1):
        net.train()
        loss_arr = []
        for batch, data in enumerate(loader_train, 1):
            # forward pass
            label = data['label'].to(device)
            input = data['input'].to(device)
            output = net(input)
            # backward pass
            optim.zero_grad()
            loss = fn_loss(output, label)
            loss.backward()
            optim.step()

            # 손실함수 계산
            loss_arr += [loss.item()]
            print("TRAIN: EPOCH %04d / %04d | BATCH %04d / %04d | LOSS %.4f" %
                  (epoch, num_epoch, batch, num_batch_train, np.mean(loss_arr)))

            # Tensorboard 저장하기
            label = fn_tonumpy(label)
            input = fn_tonumpy(fn_denorm(input, mean=0.5, std=0.5))
            output = fn_tonumpy(fn_class(output))

            writer_train.add_image('label', label, num_batch_train * (epoch - 1) +
                                   batch, dataformats='NHWC')
            writer_train.add_image('input', input, num_batch_train * (epoch - 1) +

```

```

        batch, dataformats='NHWC')
writer_train.add_image('output', output, num_batch_train * (epoch - 1) +
                        batch, dataformats='NHWC')

writer_train.add_scalar('loss', np.mean(loss_arr), epoch)

with torch.no_grad():
    net.eval()
    loss_arr = []
    for batch, data in enumerate(loader_val, 1):
        # forward pass
        label = data['label'].to(device)
        input = data['input'].to(device)
        output = net(input)

        # 손실함수 계산하기
        loss = fn_loss(output, label)
        loss_arr += [loss.item()]
        print("VALID: EPOCH %04d / %04d | BATCH %04d / %04d | LOSS %.4f" %
              (epoch, num_epoch, batch, num_batch_val, np.mean(loss_arr)))

        # Tensorboard 저장하기
        label = fn_tonumpy(label)
        input = fn_tonumpy(fn_denorm(input, mean=0.5, std=0.5))
        output = fn_tonumpy(fn_class(output))

        writer_val.add_image('label', label, num_batch_val * (epoch - 1) +
                             batch, dataformats='NHWC')
        writer_val.add_image('input', input, num_batch_val * (epoch - 1) +
                              batch, dataformats='NHWC')
        writer_val.add_image('output', output, num_batch_val * (epoch - 1) +
                              batch, dataformats='NHWC')

    writer_val.add_scalar('loss', np.mean(loss_arr), epoch)

    if epoch % 10 == 0:
        save(ckpt_dir=ckpt_dir, net=net, optim=optim, epoch=epoch)

writer_train.close()
writer_val.close()

# TEST MODE
else:
    net, optim, st_epoch = load(ckpt_dir=ckpt_dir, net=net, optim=optim)

```

```

with torch.no_grad():
    net.eval()
    loss_arr = []
    for batch, data in enumerate(loader_test, 1):
        # forward pass
        label = data['label'].to(device)
        input = data['input'].to(device)
        output = net(input)

        # 손실함수 계산하기
        loss = fn_loss(output, label)
        loss_arr += [loss.item()]
        print("TEST: BATCH %04d / %04d | LOSS %.4f" %
              (batch, num_batch_test, np.mean(loss_arr)))

        # Tensorboard 저장하기
        label = fn_tonumpy(label)
        input = fn_tonumpy(fn_denorm(input, mean=0.5, std=0.5))
        output = fn_tonumpy(fn_class(output))

    for j in range(label.shape[0]):
        id = num_batch_test * (batch - 1) + j
        plt.imsave(os.path.join(result_dir, 'png', 'label_%04d.png' % id),
                    label[j].squeeze(), cmap='gray')
        plt.imsave(os.path.join(result_dir, 'png', 'input_%04d.png' % id),
                    input[j].squeeze(), cmap='gray')
        plt.imsave(os.path.join(result_dir, 'png', 'output_%04d.png' % id),
                    output[j].squeeze(), cmap='gray')
        np.save(os.path.join(result_dir, 'numpy', 'label_%04d.npy' % id),
                 label[j].squeeze())
        np.save(os.path.join(result_dir, 'numpy', 'input_%04d.npy' % id),
                 input[j].squeeze())
        np.save(os.path.join(result_dir, 'numpy', 'output_%04d.npy' % id),
                 output[j].squeeze())

```

※ 코드 구현 참고 : <https://github.com/hanyoseob/youtube-cnn-002-pytorch-unet>

참고문헌

- 국토교통부 (2021). 국토위성정보 수집 및 활용기술 개발 최종보고서(20SIUE B148326 03).
- 송창우, 정지훈, 홍성재, 김대희, & 강주형. (2020). SPADE 기반 U-Net을 이용한 고해상도 위성영상에서의 도시 변화탐지. 대한원격탐사학회지, 36(6), 1579–1590.
- 이대건, 조은지, & 이동천. (2018). 딥러닝을 위한 영역기반 합성곱 신경망에 의한 항공영상에서 건물탐지 평가. 한국측량학회지, 36(6), 469–481.
- Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). Segnet: A deep convolutional encoder–decoder architecture for image segmentation. IEEE transactions on pattern analysis and machine intelligence, 39(12), 2481–2495.
- Guo, M., Liu, H., Xu, Y., & Huang, Y. (2020). Building extraction based on U-Net with an attention block and multiple losses. Remote Sensing, 12(9), 1400.
- Ji, S., Wei, S., & 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, 57(1), 574–586.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11), 2278–2324.
- Liu, W., Xu, J., Guo, Z., Li, E., Li, X., Zhang, L., & Liu, W. (2021). Building Footprint Extraction From Unmanned Aerial Vehicle Images Via PRU-Net: Application to Change Detection. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 14, 2236–2248.
- Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 3431–3440).
- Majd, R. D., Momeni, M., & Moallem, P. (2019). Transferable object-based framework based on deep convolutional neural networks for building extraction. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 12(8), 2627–2635.
- Mnih, V. (2013). Machine learning for aerial image labeling. University of Toronto (Canada).
- 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.

Ye, Z., Fu, Y., Gan, M., Deng, J., Comber, A., & Wang, K. (2019). Building extraction from very high resolution aerial imagery using joint attention deep neural network. *Remote Sensing*, 11(24), 2970.

【전자자료】 사이트명. 인터넷주소 (검색 연월일)

KDnuggets [website],

<https://www.kdnuggets.com/2020/10/most-popular-python-ides-editors.html>
(2021.9.7.).

제11장

고해상도 위성영상 기반 도로객체 추출을 위한 AI기술 접목 가능성 연구

1. 연구의 배경 및 목적
2. 주요 내용
3. 결과
4. 결론

1. 연구의 배경 및 목적

국토위성센터의 설립 및 운영을 위해 추진된 ‘국토위성정보 수집 및 활용기술 개발’ 과제(‘18.6.30 ~ ’20.12.31.)에서는 위성정사영상 및 활용 산출물 생산을 위한 기술 및 SW 개발을 수행했다. 활용 산출물 중 공간객체추출SW는 도로·건물 객체에 대해 AI 기반의 추출이 가능한 라이브러리를 포함하고 있다. 이 라이브러리는 딥러닝 모델 중 위성영상 분류에 많이 사용되는 U-Net 모델을 개선한 Deep U-Net 모델을 적용하였으며, 해당 과제의 보고서는 도로 객체 추출 결과 약 96.7%의 정확도를 보인다고 기술하였다. 다만 해당 사업에서 개발된 모델은 하나의 위성영상을 분할하여 훈련데이터 셋으로 사용한 것을 확인하였다.

공간객체추출SW에 국토위성센터가 보유한 임의의 위성영상에 적용해본 결과(그림 11-1) 객체 추출에 오탐지 확률이 매우 높은 것으로 나타났다. 따라서 AI 기술의 접목을 통해 위성영상에서 실효성 있는 결과를 추출할 수 있을지에 대한 재검토 필요성이 도출되었다. 본 연구에서는 다양한 공간객체 중 도로추출을 목적으로 기존 문헌들을 조사하여 도로탐지에 가장 많이 사용되고 있는 딥러닝 모델을 선정하여, 고해상도 영상에 적용해보고 그 성능을 직접 확인해보고자 한다.



<그림 11-1> 공간객체추출 SW 이용 AI 기반 도로객체추출 테스트 결과(좌: 위성영상, 우: 도로추출 결과(노란색 영역))

2. 주요 내용

가. 도로탐지 딥러닝 기술 동향

위성영상 또는 원격탐사에서 도로객체의 추출을 위해 딥러닝 기술이 접목된 연구 동향을 찾고 가장 많이 사용된 모델을 선정하기 위해, 아래 키워드를 사용하여 문헌을 검색하였다.

※ “Deep learning” & “Road” & {“Remote Sensing” or “Satellite”}

그 결과 현재 가장 인용횟수가 많은 논문은 Zhang 등(2018)이 137건('21.3.12. 기준)으로 개선된 U-Net(Deep Residual U-Net)을 이용해 도로를 탐지한 사례로 기존 CNN과 Residual U-Net 모델에 비해 높은 정확도를 가지는 것을 확인하였다. 문헌의 키워드를 분석한 결과 도로탐지에 가장 많이 사용된 모델은 CNN이었으며 U-Net과 FCN이 뒤를 이었으나, 인용 수 상위의 문헌은 대부분 U-Net을 다루었다. 본 연구의 목표는 도로객체를 픽셀단위로 분류(Semantic Segmentation)하는 것이기 때문에 단순히 객체를 인지하는 CNN 모델은 제외하고, 둘 중 비교적 높은 정확도를 보이는 U-Net을 우선 적용하고자 한다.

나. 시스템 환경설정

파이썬은 C언어를 기반으로 한 오픈소스 프로그래밍 언어로 사용하기 쉽고, 풍부한 머신러닝 라이브러리와 프레임워크가 제공되고 있어 많이 사용되고 있다. 파이썬을 딥러닝의 언어로 이용하기 위해서는 일반적으로 실제 PC의 로컬이 아닌 가상환경에 설치하고 사용하는데, 그 이유는 개발에 필요한 환경과 라이브러리 등의 버전이 서로 다른 환경에서 작업되었을 때 발생하는 문제를 미연에 방지하기 위함이다. 이러한 가상환경은 아나콘다(anaconda)를 설치하여 쉽게 만들 수 있다. 아래와 같이 생성된 가상환경을 구동하여, 사용자가 원하는 라이브러리 등을 설치하고 사용할 수 있다.

□ 아나콘다 설치 및 가상환경 설정

- 아나콘다 사이트(www.anaconda.com) 접속 후 다운로드 및 설치
- 아나콘다 프롬프트(Anaconda Prompt) 실행
- 가상환경 생성 명령어 실행 : `conda create -n <가상환경이름> python=<파이썬 버전>`
- 가상환경 구동 명령어 실행 : `conda activate <가상환경이름>`
- 라이브러리 설치 명령어 실행 : `pip install <라이브러리명>` / 설치 라이브러리 : Pytorch(머신러닝), Numpy(행렬 연산), Matplotlib(그래프 표현), Pandas(데이터 가공), SciPy(수학 함수) 등

다. 데이터 셋

데이터 셋(Data sets)은 크게 훈련데이터(Training sets), 검정데이터(Validation sets), 테스트데이터(Test sets)으로 구분된다. 보통 데이터 셋이 많지 않은 경우 모델을 만든 뒤 훈련데이터와 동일한 데이터를 검정데이터로 사용하기도 하지만 유효한 평가는 아니며, 테스트데이터는 반드시 훈련데이터와 검정데이터에 한 번도 사용되지 않은 자료를 사용하여야 한다. 검정데이터는 훈련데이터로 만들어진 모델들의 성능을 테스트하기 위해 사용되며, 검정데이터로부터 가장 좋은 성능을 보인 모델을 선택하여 최종적으로 테스트데이터를 이용하여 모델의 성능을 측정한다. 이후에는 전체 데이터를 모두 합쳐 다시 모델을 트레이닝하고 최종 모델을 만들게 된다.

본 연구에서는 별도의 데이터 셋 구축 없이 웹에서 무료로 제공하고 있는 데이터 셋 중에서, 도로가 레이블링(labeling) 되어있는 영상자료를 사용하고자 한다. Mnih은 박사 논문(Mnih, 2013)에서 구축한 머신러닝을 위한 항공영상 레이블링 자료를 아래 그림과 같이 웹에서 무료로 제공하고 있다(<http://www.cs.toronto.edu/~vmnih/data/>).



<그림 11-2> 도로탐지를 위한 항공사진 및 레이블링 데이터 셋(Mnih, 2013)

Mnih(2013)은 항공사진을 동일한 크기(1500×1500픽셀)로 잘라 약 1100개의 영역을 1(도로)과 0(도로 외)으로 구성된 레이블링 자료와 함께 제공하고 있다. 본 연구에서는 이 중 30개의 샘플을 다운받았으며, 하드웨어 사양을 고려하여 데이터를 512×512픽셀 크기로 나눠 사용하였다. 총 270개의 데이터 셋 중 216개, 27개, 27개로 나눠 각각 훈련데이터, 검정데이터, 테스트데이터로 사용하였으며, 훈련 데이터를 입력하는 과정에서는 영상을 좌/우, 상/하 방향으로 무작위 반전시켜 사용하였다.

라. 딥러닝 모델의 구현

1) 딥러닝 기초용어

딥러닝 모델을 구현하기에 앞서 가장 먼저 기본적인 용어에 대해 정리하고자 한다. 아래 용어들은 CNN에서 사용된 용어로, 이후 U-Net, FCN 등 CNN에서 파생된 딥러닝 모델에 사용되고 있어 해당 용어들을 이해하면 문헌의 해석 및 코드의 이해에 도움이 된다.

가) 커널 사이즈(Kernel size)

연산을 적용할 영역(시야, Window)의 크기를 의미(예: 3x3)한다.

나) 패딩(Padding)

패딩은 출력데이터의 공간적 크기정보를 조절하거나, 가장자리의 정보들이 유실되지 않기 위해 사용한다. 주로 0값을 채우는 zero padding을 많이 사용한다.

다) 스트라이드(Stride)

스트라이드는 입력데이터에 필터를 적용할 때 이동할 사이즈를 결정, 즉 커널의 스텝사이즈를 결정한다. 기본적으로 1 값을 사용하며, 예를 들어 스트라이드 2는 2칸씩 필터가 움직임을 의미한다.

라) 풀링 계층(Pooling layer)

풀링 계층은 합성곱 계층 외 또 다른 계층으로 데이터의 공간적 크기를 축소하고 이미지의 특징을 잡아내기 위해서 사용한다. 풀링에는 max pooling, average pooling 등이 있는데 max pooling은 해당 영역에서 최댓값을 찾는 방법이고, average pooling은 평균값을 계산한다.

마) 에포크(Epoch)

전체 데이터 셋에 대한 학습 횟수로 1 Epoch은 전체 데이터 셋에 대해 한 번 학습을 완료한 것을 의미한다. 과대적합(Overfitting)과 과소적합(Underfitting)에 유의하여 적절한 값을 설정해야 한다.

바) 배치 크기(Batch size)

전체 데이터 셋을 학습을 위해 나눌 때, 나뉘진 소그룹에 속하는 데이터의 수를 의미한다.

사) 이터레이션(Iteration)

1 에포크를 마치는데 필요한 배치의 개수를 의미한다. 예를 들어 전체 데이터 셋이 400개, 배치 크기가 100일 경우 이터레이션 수는 4이다.

아) 손실함수(Loss Function)

신경망의 지도학습 과정에서 학습 데이터에 대한 오차(목표 값과 결과 값의 차이)를 측정하는 척도이다.

아) 오차역전파(Error Backpropagation)

딥러닝 모델을 훈련시키는 데 있어 가장 많이 사용되는 방법으로 오차 값을 뒤로 보내면서 은닉층(Hidden Layer)에서 가지고 있는 가중치를 갱신해 나가는 방법이다.

자) 최적화(Optimizer)

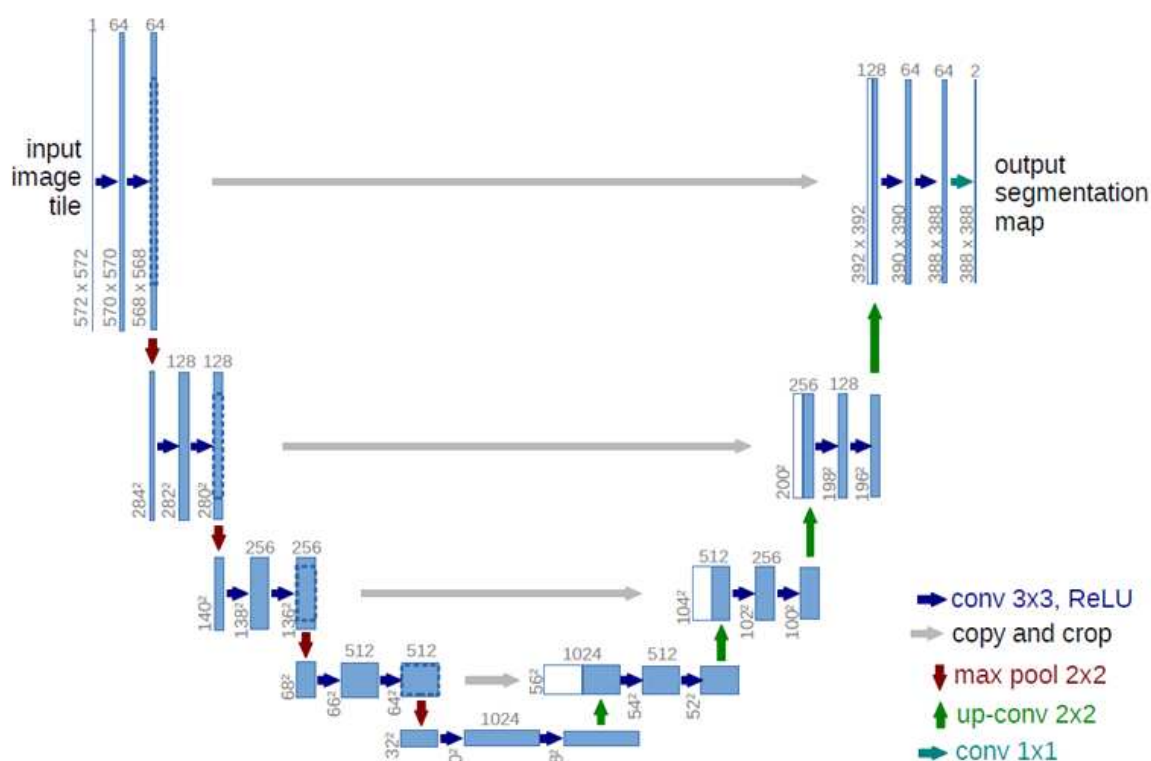
손실함수의 최솟값을 찾아나가는 일련의 과정으로, 오차역전파 과정 중 어떤 알고리즘을 사용하느냐에 따라 성능의 차이가 있다.

2) U-Net 구조 구현

Ronneberger 등(2015)에서 제시한 U-Net의 구조는 그림 11-3과 같다. U-Net은 그림에서 보는 것과 같이 U자형으로 Encoder(U 모양의 좌측, Contracting path)와 Decoder(U모양의 우측, Expansive path)로 이루어져 있다. 좌측의 Contracting path는 2개의 3x3 합성곱과 ReLU, 2x2 max pooling(빨간색 화살표)을 반복적으로 사용하며, 풀링 계층을 거치면 feature 채널 수(파란색 박스 위 숫자)가 2배 증가하는 것을 볼 수 있다. 우측에 해당되는 Expansive path에서는 2x2 up-convolution 이후 3x3 합성곱과 ReLU가 반복되는데 이때 up-convolution(초록색 화살표) 직후 Contracting path의 feature와 합쳐주는 concatenation 과정(회색 화살표)이 추가된 것을 알 수 있으며, 이 작업을 통해 Encoder 과정에서의 잃게 되는 Local 정보를 Decoder에 넘겨줄 수 있다.

부록 1은 파이썬으로 U-Net 구조를 구현한 결과이며, 코드는 github.com/hanyoseob/pytorch-unet를 참고하였다. U-Net 구조를 파이썬으로 구현하기 위해 Pytorch를 사용하였으며, torch.nn 패키지에 속해 있는 nn.Module을 이용하여 모델을 정의할 수 있다. 이렇게 U-Net 클래스를 생성한 후 __init__ 매서드와 forward 매서드를 정의하는데, __init__ 매서드에서 신경망의 계층을 정의하고 forward 매서드에서 신경망에 데이터를 어떻게 전달할지 정의할 수 있다. 먼저 __init__ 매서드에서는 코드 구현의 편의를 위해 합성곱, 배치 정규화, ReLU를 하나의 함수인 CBR2d 정의하였다. CBR2d의 입력 값은 입출력 채널 수, 커널 사이즈, 스트라이드, 패딩으로

Ronneberger (2015)에 따라 커널 사이즈와 스트라이드, 패딩은 각각 3, 1, 1로 고정하였다. 입출력 채널 수의 경우 아래 그림과 같이 1부터 1024까지 값을 주어 계층을 정의하였다. 이후 U-Net의 가장 큰 특징인 Expansive Path에서의 concatenation 과정은 torch.cat 함수를 이용하였다. 이때 그림에서 보는 것과 같이 Local 정보를 넘겨주는 feature의 행렬 크기가 받는 행렬 크기와 다른 것을 알 수 있다. 이 차이는 F.pad 함수를 이용하여 zero padding을 주어 해결할 수 있었다.



<그림 11-3> U-Net의 구조(Ronneberger, 2015)


3) U-Net 학습 파라미터

앞서 기초용어에서 설명한 것과 같이, 네트워크의 학습을 위해서는 적절한 배치 크기와 에포크 수의 설정이 필요하다. 본 연구에서는 훈련데이터와 검정데이터의 수와 데이터 내의 도로 유무를 고려하여 배치크기를 3으로 설정하였으며, 에포크 수는 40으로 하였다. 따라서 훈련 데이터 216개를 기준으로 이터레이션은 72이고 총 학습 횟수는 2,880회였다. 손실함수는 많이 사용되는 것으로 알려진 BCELoss와 Sigmoid 함수를 결합한 BCEWithLogitsLoss를 사용하였으며, 최적화는 Adam을 사용하였다.

3. 결과

1) U-Net 학습 결과

U-Net 학습은 Google Colaboratory(이하 Colab)을 이용하였다. Colab은 Google 리서치팀에서 개발한 제품으로 브라우저를 통해 Python 코드를 작성하고 실행할 수 있으며, GPU를 포함한 컴퓨팅 리소스를 무료로 제공(일일 사용량 한도 있음)하여 특히 머신러닝 및 데이터 분석용으로 많이 사용되고 있다. 그림 11-4는 U-Net 학습을 통해 얻어진 훈련데이터(주황색)와 검정데이터(하늘색)의 Loss값을 Tensorboard를 이용해 시각화한 결과이다. Loss 값은 손실함수를 이용하여 계산되며, 앞서 언급한 것처럼 Loss 값은 지도학습 과정에서 학습 데이터에 대한 오차를 의미하므로 값이 낮아질수록 목표 값에 가까운 지는 것을 의미한다. Tensorboard는 TensorFlow의 시각화 도구로 머신러닝 실험에 필요한 시각화 및 도구를 제공한다. 그래프를 통해 Loss 값이 에포크가 반복될수록 작아지는 것을 확인할 수 있으며, 두 데이터셋 모두 10번의 에포크 이후에는 0.1이하의 값을 가지는 것을 확인하였다. 최종 학습이 끝난 이후 훈련데이터는 0.06에, 검정데이터는 0.07에 수렴하였다.



<그림 11-4> U-Net 학습 결과 Loss 값 분포

2) 테스트 결과



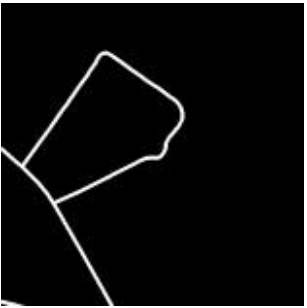

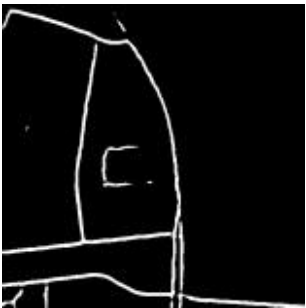

테스트는 학습과 마찬가지로 배치사이즈 3으로 진행했으며, 평균 Loss 값은 0.0977이었다. 표


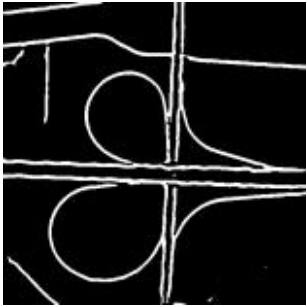
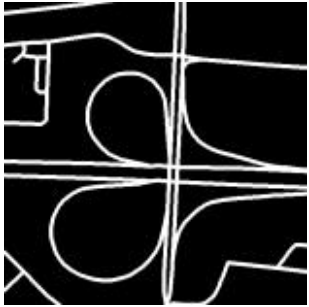


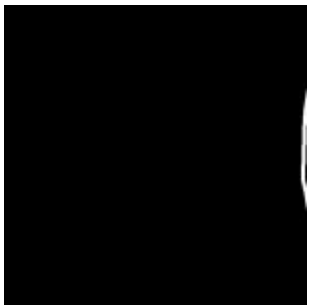


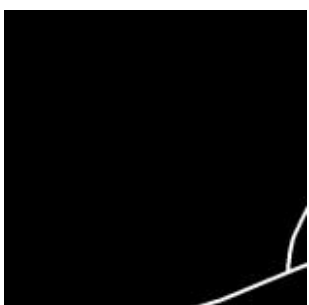
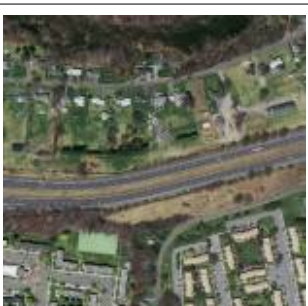
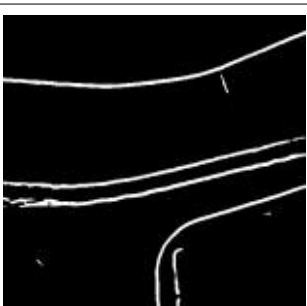


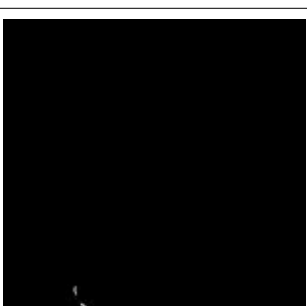
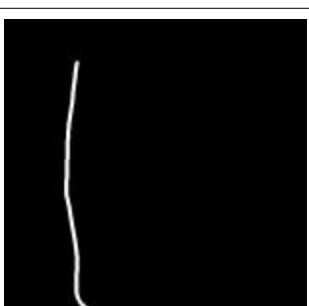
11-1은 테스트데이터 27개에 대한 U-Net 도로객체 추출 결과로 좌측 2열부터 입력자료, 출력결과(U-Net 탐지 결과), 참값(도로 레이블), 성능평가 결과를 나타낸다. 성능평가는 식 6-1 ~ 6-3의 재현율(①, Recall), 정밀도(②, Precision), F1-Score(③) 값으로 계산하였다.


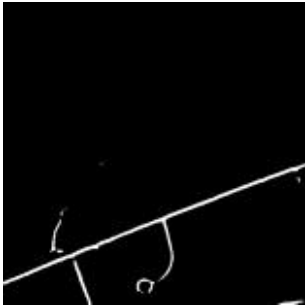


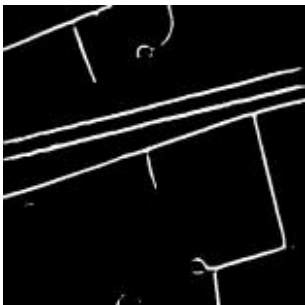
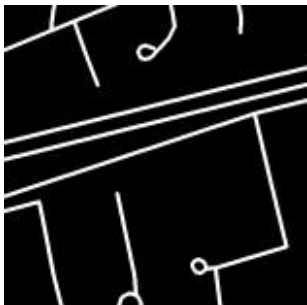


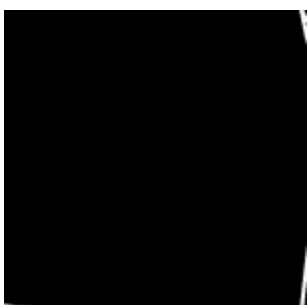

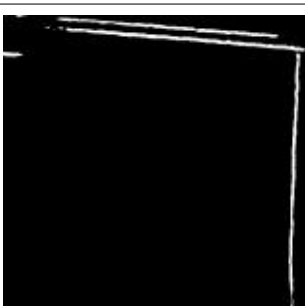
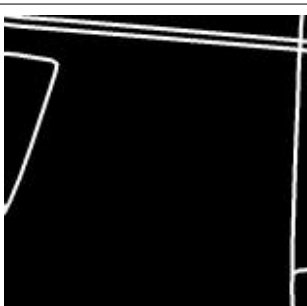
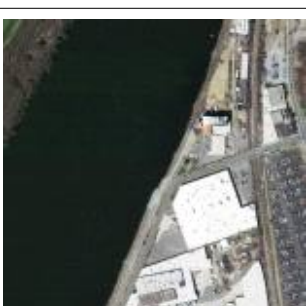

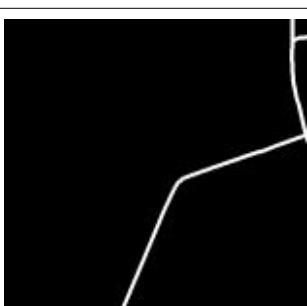
성능평가 결과 재현율, 정밀도, F1-Score의 평균값은 각각 0.47, 0.83, 0.58이었다. 다른 지표에 비해 정밀도 값이 높은 이유는 도로가 아닌 영역을 도로로 오탐지 하는 경우가 거의 없기 때문으로 사료된다. 재현율과 정밀도의 조화평균인 F1-Score 값을 확인한 결과 값이 0.3 이하인 경우(ID 4, 7, 27)는 3개였다. 이 중 ID 4와 7은 일반 도로(아스팔트)가 아닌 농경지와 인접한 마을 도로(비포장 도로)였는데, 대부분의 학습데이터가 아스팔트 등으로 포장된 도로였기 때문에 낮은 값을 보인 것으로 추정된다. 향후 학습데이터에서 도로 피복(포장, 비포장 등)에 따라 레이블링을 구분하고 충분한 데이터셋을 확보하여 학습하면 성능을 개선할 수 있을 것으로 사료된다.





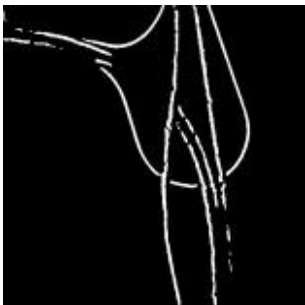
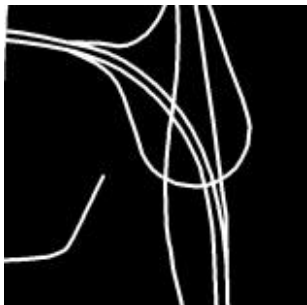


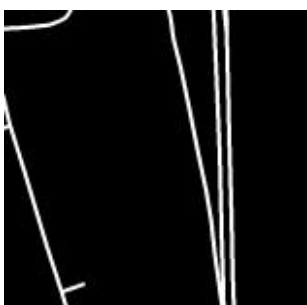

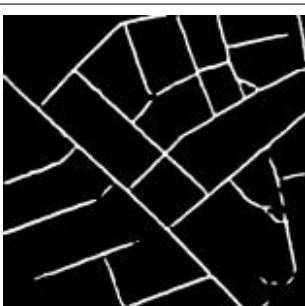
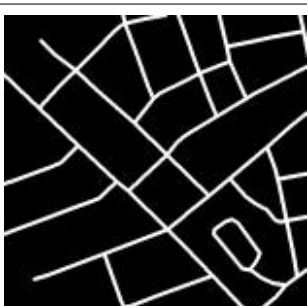

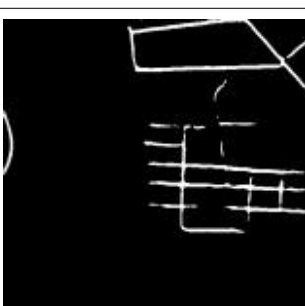
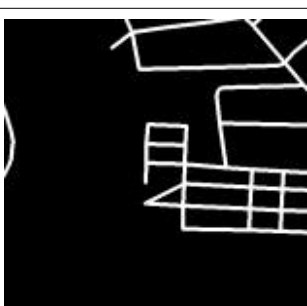
아래 표 11-1의 그림과 같이 성능평가를 육안평가와 동시에 확인한 결과, 도로로 레이블링 되지 않은 영역 중 도로로 추출된 결과를 확인 할 수 있었다. 이때 특정 결과(ID 2, 15, 21)에서 탐지된 도로가 오히려 육안 분석 상 실제 도로로 확인되었으며, 이는 본 연구에서 사용된 데이터 셋의 도로 레이블이 성능을 파악하는데 문제가 있음을 알 수 있었다. 따라서 좀 더 정확한 참값을 사용하면 정량적 평가 결과가 달라질 수 있을 것으로 판단된다.








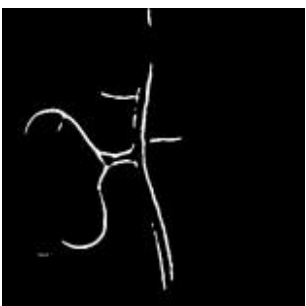


<표 11-1> U-Net 도로객체 추출 테스트 결과






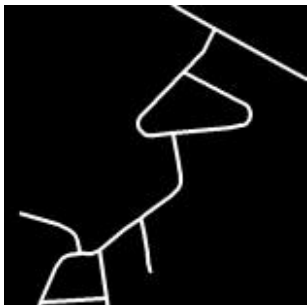









ID	입력자료	U-Net 탐지 결과	도로 레이블(참값)	성능평가 결과
1				① 0.3312 ② 0.9906 ③ 0.4965
2				① 0.7350 ② 0.8927 ③ 0.8062

ID	입력자료	U-Net 탐지 결과	도로 레이블(참값)	성능평가 결과
3				① 0.6649 ② 0.9433 ③ 0.7800
4				① 0.000 ② 0.000 ③ 0.000
5				① 0.7025 ② 0.9208 ③ 0.7970
6				① 0.5321 ② 0.9085 ③ 0.6712
7				① 0.0440 ② 1.0000 ③ 0.0842

ID	입력자료	U-Net 탐지 결과	도로 레이블(참값)	성능평가 결과
8				① 0.3473 ② 0.9148 ③ 0.5035
9				① 0.6065 ② 0.8911 ③ 0.7217
10				① 0.3884 ② 0.3858 ③ 0.3871
11				① 0.3980 ② 0.7829 ③ 0.5277
12				① 0.6987 ② 0.8950 ③ 0.7848

ID	입력자료	U-Net 탐지 결과	도로 레이블(참값)	성능평가 결과
13				① 0.6484 ② 0.9350 ③ 0.7658
14				① 0.4767 ② 0.8947 ③ 0.6220
15				① 0.4317 ② 0.6134 ③ 0.5067
16				① 0.6402 ② 0.9398 ③ 0.7616
17				① 0.5073 ② 0.8969 ③ 0.6481

ID	입력자료	U-Net 탐지 결과	도로 레이블(참값)	성능평가 결과
18				① 0.6721 ② 0.9163 ③ 0.7754
19				① 0.4506 ② 0.9060 ③ 0.6019
20				① 0.2098 ② 0.9205 ③ 0.3417
21				① 0.3419 ② 0.4965 ③ 0.4050
22				① 0.4887 ② 0.8991 ③ 0.6332

ID	입력자료	U-Net 탐지 결과	도로 레이블(참값)	성능평가 결과
23				① 0.6835 ② 0.9172 ③ 0.7833
24				① 0.5297 ② 0.9314 ③ 0.6753
25				① 0.6954 ② 0.8757 ③ 0.7752
26				① 0.4894 ② 0.8907 ③ 0.6317
27				① 0.0701 ② 0.7306 ③ 0.1280

4. 결론

본 연구는 AI 기술의 성능을 확인하고, 이를 이용하여 지상의 관심객체에 대해 자동 추출이 가능한지 검토하기 위하여 시작되었다. 또한, AI기술이 원격탐사 및 영상처리 분야에서 활발하게 사용됨에 따라 향후 AI 기술 활용을 위한 국토위성센터의 역량 강화 등에 그 목적이 있다.

본 연구에서는 딥러닝 기초 이론에 대해 파악하고 U-Net을 실제로 구현해보았으며, 항공사진을 바탕으로 도로탐지를 위한 네트워크를 학습시키고 성능을 평가해보았다. 그 결과 도로와 유사한 광학 특성을 갖는 건물 혹은 나지 등의 지역이 탐지되는 오탐지율이 낮고 고속도로 등 큰 도로 외에 이면도로 등이 잘 추출되는 것으로 미루어 보아 딥러닝을 이용한 도로 객체 추출 가능성을 확인할 수 있었다. 또한 정확도, 정밀도, F1-Score 성능지표를 이용하여 정량적 평가를 수행하였으며, 평균 F1-Score가 0.5783로 기록되어 기대에 미치지 못하는 못하였으나, 참값으로 추정된 도로 레이블링 자료가 일부 부정확하여 향후 다양한 도로 피복에서의 충분한 데이터셋을 확보하여 개선할 수 있을 것으로 사료된다.

본 연구를 통해 AI 기술을 이용하여 도로객체의 탐지 가능성과 함께 충분한 학습데이터가 필요한 것을 확인하였다. 이에 다양한 광학센서에서 관측된 도로영상과 레이블링 데이터를 확보하는 것이 필요할 것으로 사료된다. 이와 함께 국토위성 정밀정사영상을 이용하여 국토위성에서 어떤 성능을 보이는지도 테스트 할 예정이다. 이때 본 연구에서 U-Net 성능을 확인한 지역이 비교적 주변 건물과 그림자의 영향을 덜 받는 저층 건물밀집지 임을 고려해 단계적으로 적용(예: 고속도로→국도→도심지 순)하여 테스트 할 예정이며, U-Net 외의 개선된 알고리즘을 적용하여 국토위성에서 자동으로 도로객체가 추출될 수 있기를 기대한다.

참고문헌

- Mnih, V. (2013). Machine learning for aerial image labeling. University of Toronto (Canada).
- 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.
- Zhang, Z., Liu, Q., & Wang, Y. (2018). Road extraction by deep residual u-net. IEEE Geoscience and Remote Sensing Letters, 15(5), 749-753.
- U-Net 이론 참고 <https://www.youtube.com/channel/UCpujNlw4SUpgTU5rrDXH0Jw/featured>(‘21.12.2.)
- 파이썬 U-Net 소스코드 참고 <https://github.com/hanyoseob>(‘21.12.2.)

부록

부록 1. 파이썬으로 구현한 U-Net 구조

```
import torch
import torch.nn as nn

class UNet(nn.Module):
    def __init__(self):
        super(UNet, self).__init__()
        def CBR2d(in_channels, out_channels, kernel_size=3, stride=1, padding=1, bias=True):
            layers = []
            layers += [nn.Conv2d(in_channels=in_channels, out_channels=out_channels,
                                  kernel_size=kernel_size, stride=stride, padding=padding,
                                  bias=bias)]
            layers += [nn.BatchNorm2d(num_features=out_channels)]
            layers += [nn.ReLU()]
            cbr = nn.Sequential(*layers)
            return cbr

        # Contracting path
        self.enc1_1 = CBR2d(in_channels=1, out_channels=64)
        self.enc1_2 = CBR2d(in_channels=64, out_channels=64)
        self.pool1 = nn.MaxPool2d(kernel_size=2, ceil_mode=True)
        self.enc2_1 = CBR2d(in_channels=64, out_channels=128)
        self.enc2_2 = CBR2d(in_channels=128, out_channels=128)
        self.pool2 = nn.MaxPool2d(kernel_size=2, ceil_mode=True)
        self.enc3_1 = CBR2d(in_channels=128, out_channels=256)
        self.enc3_2 = CBR2d(in_channels=256, out_channels=256)
        self.pool3 = nn.MaxPool2d(kernel_size=2, ceil_mode=True)
        self.enc4_1 = CBR2d(in_channels=256, out_channels=512)
        self.enc4_2 = CBR2d(in_channels=512, out_channels=512)
        self.pool4 = nn.MaxPool2d(kernel_size=2, ceil_mode=True)
```

```

self.enc5_1 = CBR2d(in_channels=512, out_channels=1024)

# Expansive path
self.dec5_1 = CBR2d(in_channels=1024, out_channels=512)
self.unpool4 = nn.ConvTranspose2d(in_channels=512, out_channels=512,
                                   kernel_size=2, stride=2, padding=0, bias=True)
self.dec4_2 = CBR2d(in_channels=2 * 512, out_channels=512)
self.dec4_1 = CBR2d(in_channels=512, out_channels=256)
self.unpool3 = nn.ConvTranspose2d(in_channels=256, out_channels=256,
                                   kernel_size=2, stride=2, padding=0, bias=True)
self.dec3_2 = CBR2d(in_channels=2 * 256, out_channels=256)
self.dec3_1 = CBR2d(in_channels=256, out_channels=128)
self.unpool2 = nn.ConvTranspose2d(in_channels=128, out_channels=128,
                                   kernel_size=2, stride=2, padding=0, bias=True)
self.dec2_2 = CBR2d(in_channels=2 * 128, out_channels=128)
self.dec2_1 = CBR2d(in_channels=128, out_channels=64)
self.unpool1 = nn.ConvTranspose2d(in_channels=64, out_channels=64,
                                   kernel_size=2, stride=2, padding=0, bias=True)
self.dec1_2 = CBR2d(in_channels=2 * 64, out_channels=64)
self.dec1_1 = CBR2d(in_channels=64, out_channels=64)

self.fc = nn.Conv2d(in_channels=64, out_channels=1, kernel_size=1, stride=1,
                    padding=0, bias=True)

def forward(self, x):
    enc1_1 = self.enc1_1(x)
    enc1_2 = self.enc1_2(enc1_1)
    pool1 = self.pool1(enc1_2)
    enc2_1 = self.enc2_1(pool1)
    enc2_2 = self.enc2_2(enc2_1)
    pool2 = self.pool2(enc2_2)
    enc3_1 = self.enc3_1(pool2)
    enc3_2 = self.enc3_2(enc3_1)
    pool3 = self.pool3(enc3_2)
    enc4_1 = self.enc4_1(pool3)
    enc4_2 = self.enc4_2(enc4_1)
    pool4 = self.pool4(enc4_2)

```

```

enc5_1 = self.enc5_1(pool4)
dec5_1 = self.dec5_1(enc5_1)
unpool4 = self.unpool4(dec5_1)
diffY = unpool4.size()[2] - enc4_2.size()[2]
diffX = unpool4.size()[3] - enc4_2.size()[3]
enc4_2 = F.pad(enc4_2, [diffX // 2, diffX - diffX // 2,
                        diffY // 2, diffY - diffY // 2])
cat4 = torch.cat((unpool4, enc4_2), dim=1)
dec4_2 = self.dec4_2(cat4)
dec4_1 = self.dec4_1(dec4_2)
unpool3 = self.unpool3(dec4_1)
diffY = unpool3.size()[2] - enc3_2.size()[2]
diffX = unpool3.size()[3] - enc3_2.size()[3]
enc3_2 = F.pad(enc3_2, [diffX // 2, diffX - diffX // 2,
                        diffY // 2, diffY - diffY // 2])
cat3 = torch.cat((unpool3, enc3_2), dim=1)
dec3_2 = self.dec3_2(cat3)
dec3_1 = self.dec3_1(dec3_2)
unpool2 = self.unpool2(dec3_1)
diffY = unpool2.size()[2] - enc2_2.size()[2]
diffX = unpool2.size()[3] - enc2_2.size()[3]
enc2_2 = F.pad(enc2_2, [diffX // 2, diffX - diffX // 2,
                        diffY // 2, diffY - diffY // 2])
cat2 = torch.cat((unpool2, enc2_2), dim=1)
dec2_2 = self.dec2_2(cat2)
dec2_1 = self.dec2_1(dec2_2)
unpool1 = self.unpool1(dec2_1)
diffY = unpool1.size()[2] - enc1_2.size()[2]
diffX = unpool1.size()[3] - enc1_2.size()[3]
enc1_2 = F.pad(enc1_2, [diffX // 2, diffX - diffX // 2,
                        diffY // 2, diffY - diffY // 2])
cat1 = torch.cat((unpool1, enc1_2), dim=1)
dec1_2 = self.dec1_2(cat1)
dec1_1 = self.dec1_1(dec1_2)

x = self.fc(dec1_1)
return x

```

제12장

후속위성 개발 환경 분석을 위한 정책 및 기술동향 조사

-
1. 연구의 배경 목적
 2. 국토위성(차세대중형위성) 기획 및 개발과정 분석
 3. 해외 주요 위성 개발 및 운영 현황
 4. 결론

1. 연구의 배경 및 목적

국토위성(차세대중형위성 1호)은 2021년 3월 22일 한국시간 오후 3시에 카자흐스탄 바이코누르 우주센터에서 발사에 성공해, 앞으로 약 4년간(설계 임무수명) 한반도와 주요 관심지역을 고해상도(흑백 0.5m, 컬러 2m)로 관측하는 임무를 수행할 예정이다. 차세대중형위성 시리즈는 2012년 4월 기획연구에 착수해 정부부처를 대상으로 수요조사를 실시하고, 총 12기의 차세대중형위성 개발을 위한 로드맵을 수립했다(교육과학기술부, 2012). 국토위성 1호는 국토의 이용, 자원관리, 재난 대응 등 위성기반 국토 관리 및 공간정보 구축 관련 업무의 효율적 지원을 위해 2015년 3월 개발에 착수하여 위성 개발 및 발사까지 약 6년이 소요되었다. 국토위성의 설계 임무수명과 위성 개발 소요기간을 고려해 볼 때, 위성 발사와 동시에 후속위성에 대한 준비가 필요하다. 천리안 위성을 운영·활용하는 국가기상위성센터는 2010년 천리안 1호 발사성공과 동시에 천리안 2호 개발을 위한 예비타당성 조사를 통과해 천리안 2호 개발에 착수하였으며, 2018년 천리안 2A호 발사성공 이후 후속 정지궤도 기상위성 개발을 위한 기획연구를 수행하고 2021년 예비타당성 조사 대응 기획연구에 착수한 상황이다. 따라서 국토위성을 운영·활용하는 국토위성센터 역시 위성의 공백 없는 이·활용을 위해 국토위성 1호의 발사와 동시에 후속 위성에 도입을 위해 「영상정보 획득체계 다변화 연구」사업을 2021년 8월부터 추진 중에 있다.

본 연구에서는 국토위성의 기획 및 개발 추진 전 과정을 분석하고, 현재 개발·운영 중인 해외 주요 고해상도 위성의 현황을 파악하였다. 국토위성은 위성의 공공 활용 및 민간 위성산업 활성화를 위해 개발한 차세대중형위성 시리즈의 첫번째 위성으로, 기존 위성의 제한적 활용에서 다양한 분야의 위성정보 활용 확대를 위해 개발되었다. 그러나 공공수요 충족을 위한 최초의 위성개발이다 보니 기존과 같이 위성 개발을 중심으로 사업이 수행되었다. 따라서, 실제 위성의 활용부처인 국토교통부의 위성 활용과 관련된 의견이 위성 개발 사업에 100% 반영되는데 한계가 있었다. 이에 국토위성 기획 및 개발과정에서의 문제점과 한계점을 분석하고 이에 대한 개선사항을 마련하였다. 국토위성 기획 과정 분석에서는 기획보고서, 예비타당성 조사 보고서 등을 바탕으로 국토위성 개발 관련 정책적 의사결정 사항, 추진방향, 타당성 등을 정리·분석하고, 위성개발 단계에서는 위성개발을 중심으로 계획된 사용자요구사항(URD) 및 위성 개발 과정에서의 주요 이슈사항을 분석했다. 또한, 해외 고해상도 위성 현황 파악에서는 현재 운영 중인 주요 위성의 수명, 무게, 궤도, 탑재체 해상도, 촬영폭 등의 현황을 분석하였다. 본 연구의 결과물인 국토위성의 개발 추진 과정 분석 결과와 해외 위성의 현황 분석 자료는 국토위성센터의 후속위성 도입 과정에서 참고자료로 활용할 예정이다.

2. 국토위성(차세대중형위성) 기획 및 개발과정 분석

2012년 차세대중형위성 기획연구가 종료된 이후, 국토위성의 개발을 위한 예비타당성 조사를 위해 2013년부터 국토교통부와 과학기술정보통신부는 각각 「미래 성장동력 확보를 위한 공간정보 위성 탑재체 개발 기획보고서(국토교통부, 2013)」, 「차세대중형위성개발 선행연구(미래창조과학부, 2014)」 기획연구에 착수했다. 본 보고서에서는 부처별 기획연구 보고서 및 예비타당성 결과 보고서 분석을 통해 국토위성 개발 기획 단계의 기술적, 정책적인 사항에 대해 분석을 수행하였다. 또한 2015년 국토위성이 개발에 착수한 후 개발과정에서의 정책적인 이슈사항에 대한 분석을 수행하였다.

가. 국토위성 기획 과정 주요 이슈사항

1) 기술적 타당성

국토위성은 국토의 자원관리, 재난재해 감시 등 지상의 정밀관측을 목표로 기획되었다. 기획 당시 국토위성의 목표해상도는 흑백 기준 1m(MS 4m)의 고도 500~700km의 임무궤도로 운영하고 설계 임무기간은 최소 4년, 관측 폭은 15km 이상으로 설계되었다. 또한, GCP(Ground Control Point) 없이 1:50,000의 지도제작, GCP를 이용해 1:25,000의 지도 제작이 가능해야하고, roll, pitch 방향으로 각각 $\pm 56^\circ$, $\pm 30^\circ$ tilt 할 수 있도록 설계되었다(미래창조과학부, 2014). 예비타당성 조사를 거치며 대부분의 요구조건은 반영되었으나, 가장 핵심적인 공간해상도 부분이 흑백기준 0.5m로 상향되었다. 예비타당성 조사에서는 다목적실용위성 3A가 0.55m의 정밀관측이 가능하므로, 현재 국내 최고수준인 0.5m로 요구 성능 상향을 요구하였다(한국과학기술기획평가원, 2014). 이에 따라 당초 기획의 1:25,000 지도제작보다 더 상향된 1:5,000 등의 지도제작 가능여부 등이 검토되었다. 이는 최초 기획단계에서 위성 활용분야에 대한 분석과, 위성의 가용 성능에 대한 분석이 부족했기 때문에 예비타당성 조사에서 위성의 성능이 변경되었다. 향후 후속위성 개발 시에는 기획단계에서부터 최종 산출물에 대한 명확한 리스트화가 필요하며, 위성 개발 시 개발 가능한 위성의 성능을 사전 분석하여, 실제 개발 시 이를 검증할 수 있는 지표를 마련하고 이에 대한 확인 및 검증이 필요하다.

2) 경제적, 정책적 타당성

예비타당성 보고서는 기획연구를 통해 도출된 정책적인 추진근거에 대한 타당성은 인정했으나,

경제적 타당성의 부족과 다목적실용위성과의 중복 문제 등을 지적하였다(한국과학기술평가원 2014). 경제적 타당성의 경우, 방문 인터뷰 방식의 수요조사 수행에 따른 질문 설계 가변성 등 신뢰성 부족, 위성영상 무상배포 가정에 따른 수요 과대 추정, 향후 수요 증가 예측에 대한 객관적 자료 부족 등이 지적되었다. 이로 인해 지도제작, 환경, 해양, 지질자원, 임업 분야 등에 대한 활용분야의 경제적 타당성 부분이 반영되지 못하고, 영상 판매수익, 위성 수출에 대한 편익만 반영되어 기획연구를 통해 제시한 총 편익 5,303억의 약 55%수준인 2,945억 원으로 축소되었다. 중복성의 경우, 국토위성, 다목적실용위성 모두 고해상도 위성으로 성능의 차이가 없으며, 재난, 지표면 분석 등의 임무 등이 중복으로 나타났다. 향후 후속 국토위성 기획 시에는 위성 수요에 대한 조사 방안 및 수요 예측 분석 방안의 구체화, 타 고해상도 저궤도 위성과의 차별화된 임무수행을 위한 국토위성만의 고유 업무 및 활용분야 제시가 반드시 필요하다고 판단된다.

나. 국토위성 개발 과정 주요 이슈사항

2014년 12월 국가우주위원회에서 차세대중형위성 1단계 개발사업 계획이 의결되고, 2015년 2월 차세대중형위성 개발사업 추진위원회에서 사업추진이 의결됨에 따라 2015년 3월부터 본격적으로 국토위성 1호가 개발되었다. 이후 2017년까지 약 1년 10개월 간 설계 작업을 진행 후, 2019년 11월까지 주요 부품개발 및 조립을 수행하고, 각종 열진공 시험, 전자파 시험 등의 내부 환경시험을 2021년 1월까지 진행하였다.

전체적으로 위성 개발은 큰 문제없이 진행되었지만, 위성개발 초기 설계 단계에서 사용자 요구사항 정의 시 위성의 가동범위, 촬영용량, 위치정확도 등에서 위성의 주요 임무와 활용 목적이 충분히 고려되지 못했다. 또한 최초 기획연구에서 포함되어 있던 활용부처의 위성영상 직수신 부분이 예타 대응 및 위성 개발 과정에서 누락되어 활용부처 위성센터에서 위성정보를 직수신 할 수 없는 구조로 국토위성이 개발되고, 국토위성센터가 설립되었다.

1) 사용자요구사항

사용자요구사항의 경우 수립 시점의 적절성, 요구사항 내 콘텐츠의 적절성에 대해 분석하였다. 2015년 3월 국토위성 개발에 착수하였으나, 사용자요구사항은 2015년 11월에 확정되었다. 사용자요구사항은 위성을 기획하는 단계에서 실제 활용부처에서 위성을 어떠한 용도로 어떻게 활용할지에 대한 의견을 수렴해 위성개발 사업을 착수하기 전 완성이 되어 해당 내용이 예산, 사업기간 등

에 반영이 되었어야 하는데, 이미 위성 개발이 확정되고, 예산과 사업기간이 정해진 단계에서 사용자 요구사항의 수립은 사용자요구사항 수립에 매우 제한적인 환경이었다.

사용자요구사항 콘텐츠의 경우 위성 개발의 관점에서는 충분하게 내용이 반영되었으나, 활용관점에서는 충분한 검토가 이루어지지 않았다. 위성의 고도, 수명, 관측 폭, 지상해상도 등 위성 개발에 필요한 요구사항들은 정의되어 위성을 개발할 수 있었으나, 위성임무에 대한 이해나 위성활용을 고려한 구체성이 부족했다. 대표적인 케이스가 위성의 임무궤도에서 위상차이다. 2015년 사용자요구사항에서는 국토위성2호의 위상차를 1호의 임무궤도상에서 180° 차이로 정의하긴 하였으나, 향후 최종 확정이라는 단서를 남겼었고 이를 국토위성 2호 개발에 앞서 2017년 6월에 확정지었다. 또한, 위성의 관심 관측영역(ROI)를 한반도 전체영역으로만 정의하고, 위성의 가동범위에 따른 FOR(Field Of Regard)의 정의가 누락되었으며, 위성 관측 운영모드에서도 스트립, 스팟, 스테레오로만 정의하고, 각 촬영모드별 촬영범위나 촬영가능 용량 등에 대한 내용은 포함되지 않았다. 측위정밀도의 경우 국토위성의 주요 목적이 지도제작 등을 위한 공간정보 구축임에도 불구하고 70m(CE90) 수준으로 매우 낮게 정의하였다. 향후 후속위성 도입 시에는 국토위성 1호, 2호 개발시 드러난 사용자요구사항의 문제점 등을 개선할 수 있도록 위성의 주활용부처의 충분한 검토와 의견반영이 필요하며 위성 기획단계에서부터 사용자요구사항에 대한 검토와 사업 추진 전에 사용자요구사항 확정이 필요하다.

2) 위성영상 수신 관련

국토위성은 최초 기획연구 수행 시 위성의 주 활용부처도 영상을 수신할 수 있도록 기획되었으나, 예비타당성 조사 시 해당 부분에 대한 구체적인 분석과 근거자료가 없어 반영되지 않았다. 이후 국토부에서는 위성의 효율적인 활용을 위해 국토위성 직수신을 요청하고 이에 대한 사항을 제21회 우주개발진흥실무위원회(2015.11.23.)에서 심의하였으나 중복투자 등의 이유로 국토부의 별도 직수신 시스템 설치 불가로 의결되었다. 현재 국가기상위성센터의 경우 천리안 위성의 정보를 직접 수신 받고 있으며, 한국항공우주연구원이 부수신을 담당하고 있다. 기상위성센터는 천리안 2A호 개발 시 직수신을 포함한 지상시스템 구축에 대한 부분을 위성개발과 별도로 예비타당성 조사를 수행하여 직수신 및 지상시스템을 구축하였다. 위성정보 직수신 등 영상처리·활용에 대한 인프라 구축은 위성정보의 실시간적인 수신·분석을 통해 재난 등 긴급 상황에 즉시 활용할 수 있을 뿐만 아니라, 영상의 품질 분석을 통한 영상 품질향상 등이 가능하다. 그러나 국토부의 경우 국토위성센터 등 전담 조직의 부재, 위성개발 경험 및 관련 지식 부족 등의 사유로 직수신에 대한 사항을 당초 기획

단계에서부터 반영하지 못하였다. 현재 국토위성센터는 한국항공우주연구원에서 수신한 국토위성 데이터를 바로 전송받을 수 있도록 시스템을 구축하였으나, 향후 후속위성 개발 시 후속위성의 영상 수신 관련 사항들을 점검하고, 직수신 및 지상시스템 구축을 위한 제도적, 경제적 타당성 마련 등의 작업이 필요할 것으로 판단된다.

다. 시사점

국토위성 1호가 발사에 성공하고 2호가 개발 중에 있지만, 후속위성 도입 등을 위해서는 관련된 정책적, 기술적 방향에 대한 목표와 전략 수립이 필요하고, 이를 위해 선행적으로 고려해야 하는 부분이 있다. 첫째, 명확한 임무목적 설계가 필요하다. 다목적실용위성과의 중복성 뿐만 아니라, 위성기획 시 명확한 목적 설계가 이루어지지 않았기 때문에, 위성의 요구사항을 목적에 맞게 도출하지 못했었다. 따라서 위성개발 기획단계에서 명확한 목표설정 및 상세한 기획연구를 통해 위성개발에 대한 사전 타당성 분석이 필요하다. 둘째, 위성 활용 수요와 경제적 효과 등에 대한 구체적인 분석이 필요하다. 기획단계에서 국토위성 개발에 대해 다양한 활용분야와 수요 예측을 제시 하였으나 이에 대한 객관성, 신뢰성이 부족했으며, 위성의 효율적 활용 등을 위해서는 실제 국토위성 1호, 2호를 운영하면서 발생하는 수요에 대한 분석과 지속적인 공공 및 민간 분야 활용수요 발굴 분석이 기획단계에서 반드시 병행되어야 한다. 셋째, 위성 개발 전 과정에 대한 이해와 활용분야에서 필요한 위성의 요구사항을 바탕으로 한 후속위성 업무 설계가 필요하다. 국토위성 1호, 2호의 경우 최초 중형위성 개발에 초점이 맞춰져 위성에 활용분야에 대한 분석과 위성활용 부처에 대한 요구사항에 대한 검토·반영이 제한적이었다. 후속위성 개발단계에서는 활용 부처의 명확한 활용목적 및 임무설정이 필요하며 개발부처에서는 활용부처의 위성정보 활용 극대화를 위한 개발 추진 등이 필요하다.

3. 해외 주요 위성 개발 및 운영 현황

2018년 기준 지난 10년간 지구관측 위성을 발사한 국가는 35개국으로 향후 10년간 지구관측 위성을 발사하는 국가는 48개로 증가할 것으로 예측된다(김은정, 2018). 또한, 지구관측 위성은 위성 개발비용의 감소와 활용분야의 증가로 인해 2028년까지 총 1,600여기 이상이 발사될 예정이다(Euroconsult, 2020). 세계 주요국들의 정부주도 위성개발과 더불어 Newspace 시대로의 전환과정에 민간기업의 상업용 지구관측위성의 비율도 꾸준히 증가해 위성영상 획득 경로

또한 다양화 되고 있다. 본 연구에서는 해외에서 개발, 운영 중인 고해상도 광학위성, SAR 위성의 주요재원 등의 현황을 분석하였다.

고해상도 광학위성은 미국, 유럽, 중국 등 다양한 국가에서 발사·운영 중에 있으며, 정보취득의 신속성, 편의성 등을 위해 지속적으로 다양한 위성들이 개발되고 있다. 분석대상 위성은 위성의 운영 현황 정보를 파악할 수 있는 UCS(Union of Concerned Scientists) Satellite database의 정보를 활용해 총 12기의 고해상도 광학위성과 3기의 SAR 위성에 대해 분석을 수행하였다. 해외위성 조사는 국토위성의 사용자 요구사항 항목을 참고하여 수명, 중량, 궤도, 관측폭, 해상도, 파장대역, 촬영모드, 측위 정밀도 등의 항목으로 구성하였다. SAR 위성 역시 광학위성과 유사한 항목으로 분석을 수행하였다.

가. 고해상도 광학위성 개발 및 운영 현황

1) 고해상도 광학위성(대형)

가) WorldView 시리즈

WorldView 위성은 미국 국방부 산하 NGA(National Geospatial-Intelligence Agency)에서 고해상도 위성정보 제공을 목적으로 2003년 'NGA NextView Program'으로 개발에 착수해 2009년 1호, 2014년 2호, 2014년 3호, 2016년 4호를 발사하였다. WorldView-1은 2016년 6월 공식임무가 종료되었고, WorldView-4는 2019년 자이로스코프 컨트롤의 이상으로 공식 임무를 종료함에 따라 현재 WorldView-2/3만 운영 중에 있다(eoPortal Dictionary, 2021.5.7.).

WorldView-3는 약 620km 상공에서 태양동기궤도로 운영 중이며, 해상도는 흑백 0.31m(MS 1.24m)이며, 관측폭은 13.1km로 스트립, 스왑, 스테레오 촬영이 가능하고, 측위정밀도는 GCP 보정없이 3.5m(CE90)로 알려져 있다(N2YO, eoPortal Dictionary, 2021.5.7.).

나) Pleiades-HR / Pleiades-NEO 시리즈

Pleiades-HR은 프랑스 CNES(Centre National d'Etudes Spatiales)의 주관으로 이탈리아, 오스트리아 등의 공동 투자를 받아 2011년에 처음 발사한 위성이다. 후속위성인 Pleiades-Neo (총 4기)는 민간 기업인 Airbus Defence & Space에서 개발 중이며, 2021년 4월 20일에 Pleiades-Neo 1호, 2021년 8월 17일에 2호 발사에 성공했다. Pleiades-HR은 약 704km 상공에서 태양동기궤도로 운영 중이며, 해상도는 흑백 0.7m(MS 2.8m)로 촬영 후 후처

리를 통해 0.5m(MS 2.0m)로 제공이 가능하며, 관측폭은 20km로 스트립, 스팟, 스테레오 촬영이 가능하고, 측위정밀도는 GCP 보정없이 3~12m(CE90)로 알려져 있다(eoPortal Dictionary, 2021.5.18.). Pleiades-Neo는 2022년까지 2대를 추가로 발사해 총 4대로 운영 예정이다. Pleiades-Neo는 Pleiades-HR 대비 관측폭은 20km에서 14km로 줄었으나, 해상도는 흑백 0.3m(MS 1.2m)로 크게 향상되었으며 파장대역 또한 기존 가시영역, 근적외선 영역 등 4개 밴드에서 deep blue, red edge가 추가되어 총 6개의 밴드를 제공한다. Pleiades-Neo는 하루 200만 ㎢ 촬영이 가능하며, GCP 보정없이 5m(CE 90) 이하의 정확도를 가지고 있다(AirBus Defence & Space, 2021.11.16.)

다) Resurs-P 시리즈

Resurs는 러시아의 지구관측 위성으로 Resurs-P는 광학, Resurs-O는 SAR 위성을 의미한다. Resurs-P 위성은 위성에 고해상도 센서(GEOTON-L1), 중해상도 및 저해상도 센서(WCMI-HR and WCMI-MR), Hyper-Spectral 센서(Hyperspectral Apparatus) 등 총 4개의 영상 센서를 탑재한 초대형 위성이다. 고해상도 센서는 해상도 1m급(흑백 기준) 영상을 촬영하며, 중저해상도 센서를 통해 해상도 12~60m(흑백 기준)의 영상을 촬영하며, Hyper-Spectral 센서는 약 25~30m의 해상도로 96개의 밴드(0.4 - 1.1 μm)를 촬영한다(eoPortal Dictionary, 2021.5.18.). Resurs-P 현재 3기가 운영 중에 있다.

Resurs-P 고해상도 센서의 경우 해상도는 흑백 1m(MS 3~4m,) 이고, Red, Green, Blue, NIR1, NIR2 등의 5개의 파장대로 촬영이 가능하다. 관측폭은 13.1km로 스트립, 스팟, 스테레오 촬영이 가능하며, 측위정밀도는 GCP 보정없이 10m(CE90)로 알려져 있다(Innoter, eoPortal Dictionary, 2021.5.18.).

<표 12-1> WorldView, Pleiades, Resurs-P 위성 비교

구분	WorldView-3	Pleiades-NEO	Resurs-P(3호)
발사일	2014.08.13.	2021.4.29.(1호) 2021.8.17.(2호)	2016.3.13.
임무수명	7.25년 이상	10년 이상	7년 이상
중량	2,812kg	900kg	5920kg
임무궤도	620.0~621.2km (태양동기궤도)	620km (태양동기궤도)	469.9~476.5km (태양동기궤도)
위성 통과 시간 (지방시)	오후 1시 30분	오전 10시 30분	오전 10시 30분
관측폭	13.1km	14km	38km

구분		WorldView-3	Pleiades-NEO	Resurs-P(3호)
FOR (Field Of Regard)		약 1,175km ($\pm 40^\circ$ off-nadir)	약 715km ($\pm 30^\circ$ off-nadir)	약 950km ($\pm 30^\circ$ off-nadir)
지상 해상도	PAN	0.31m (0.34m, 20° off-nadir)	0.3m	1m
	MS	1.24m (1.38m, 20° off-nadir)	1.2m	3~4m
파장 대역	PAN	450~800 nm	450~800 nm	620 ~ 790nm
	MS	400~1040nm (8bands)	450~880nm (6bands)	480 ~ 790nm (5bands)
관측운영모드		스트립(Strip imaging), 스팟(Spot imaging), 스테레오(stereo imaging)		
측위정밀도(CE90) (Without GCP)		3.5m 이내	5m 이내	10m 이내

라) Gokturk-1A

Gokturk-1A 위성은 터키의 Turkish Aerospace Industries의 주도로 2009년부터 개발에 착수해 2016년 12월 발사에 성공한 고해상도 위성이다. Gokturk-1A 위성은 Pleiades-HR와 동일한 탑재체 센서인 HiRi를 사용하고 있어 해상도는 흑백 0.7m(MS 2.8m)로 촬영 후 후처리를 통해 0.5m(MS 2.0m)로 제공이 가능하며 관측폭은 15km로 스트립, 스팟, 스테레오 촬영이 가능하고, 측위정밀도는 GCP 보정없이 20m이하로(CE90)로 알려져 있다(eoPortal Dictionary, OSCAR, 2021.6.18.).

마) GaoFen 시리즈

GaoFen 시리즈 위성은 중국 CNSA (China National Space Administration) GaoFen 프로젝트를 통해 개발된 위성으로 2013년 GaoFen 1호를 처음 발사한 후 2014년 1m 이하의 GaoFen-2호를 발사하였다. 2021년 GaoFen 위성은 저해상도, 중해상도, 고해상도, SAR, Hyper 등 총 14개의 위성시리즈를 개발·운영 중에 있다(OSCAR, 2021.6.18.). 2019년 발사한 GaoFen-7은 약 500km 상공에서 태양동기궤도로 운영 중이며, 해상도는 흑백 0.8m(컬러 3.2m)이고, 관측폭은 20km로 스트립, 스팟, 스테레오 촬영이 가능하다. 스테레오 촬영의 경우 카메라 2대(Forward 26° , Backward -5°)가 있어 한번 촬영으로 스테레오 영상 구축이 가능하다(OSCAR, 2021.6.18.).

바) ALOS-3

ALOS 위성은 일본 JAXA에서 기획한 위성으로, 2006년 해상도 2.5m 광학위성 ALOS-1을 발사하고, 2013년 SAR 위성인 ALOS-2를 발사하였으며, ALOS-3(2021년 발사 예정), ALOS-4(2022년 발사 예정)를 개발하고 있다. ALOS-3는 약 670 km 상공에서 태양동기궤도로 해상도는 흑백 0.8m(컬러 3.2m)이고, 관측폭은 70km로 스트립, 스팟, 스테레오 촬영이 가능한 위성이다(JAXA 2021.6.18.).

사) CartoSat-3

CartoSat 시리즈 위성은 인도 ISRO(Indian Space Research Organization)에서 제작한 고해상도 위성으로 2007년 CartoSat-1 위성 발사를 시작으로 2019년 CartoSat-3까지 총 9대의 위성을 발사하였다. Cartosat-3위성은 해상도 흑백 0.28m(컬러 1.14m)의 해상도로, 관측폭 17km이며, 스트립, 스팟, 스테레오 촬영이 가능하다(OSCAR 2021.6.18.).

<표 12-2> Gokturk-1A, GaoFen-7, ALOS-3, CartoSat-3 위성 비교

구분		Gokturk-1A	GaoFen-7	ALOS-3	CartoSat-3
발사일		2016.12.05.	2019.11.3.	2021년(예정)	2019.11.27.
임무수명		7년 이상	8년 이상	7년 이상	5년 이상
중량		1,060kg	2,400kg	3,000kg	1,625kg
임무궤도		690.4~692.3km (태양동기궤도)	502.8~515.5km (태양동기궤도)	669km (태양동기궤도)	505.1~525.5km (태양동기궤도)
위성 통과 시간 (지방시)		오전 10시 30분	오전 10시 30분	오전 10시 30분	오전 9시 30분
관측폭		15km	20km	70km	17km
FOR (Field Of Regard)		800km	700km	750km	400km
지상 해상도	PAN	0.7m (영상처리 후 0.5m)	0.8m	0.8m	0.28m
	MS	2.8m (영상처리 후 2.0m)	3.2m	3.2m	1.14m
파장 대역	PAN	480~820 nm	450~900 nm	520~760 nm	450~900 nm
	MS	450~915nm (4bands)	450~890nm (4bands)	400~890nm (6bands)	450~912nm (4bands)
관측운영모드		스트립(Strip imaging), 스팟(Spot imaging), 스테레오(stereo imaging)			
측위정밀도(CE90) (Without GCP)		20m 이내	50m 이내	-	-

2) 고해상도 광학위성(중형)

가) DMC-3

DMC-3 위성은 영국 SSTL(Surrey Satellite Technology Ltd.)에서 중국 Twenty First Century Aerospace Technology Company Ltd.으로부터 위성 3기 개발 비용의 대부분을 투자받아 개발한 위성으로 500kg급 중형위성 3기를 2015년 발사하여 운영 중에 있다. DMC-3 위성은 발사 후 중국에서 7년간의 운영과 영상 수신권을 가지고 있어 중국의 지표관측, 재난 및 도시변화 모니터링 등의 용도로 활용되고 있다. 해상도는 off-nadir에서 흑백 0.8m(컬러 3.2m)이며, 관측폭은 23km로 스트립, 스팟, 스테레오 촬영이 가능하다. 위성 3기를 운영할 경우 위성의 동일지점 재방문 주기는 1일 이내이며, 하루 약 60만㎢ 이상을 촬영할 수 있다(eoPortal Dictionary 2021.6.18.).

나) SuperView

SuperView 위성은 중국 Beijing Space View Technology에서 개발한 상용위성으로 총 4기로 구성되며, 2기를 한 쌍으로 동일 궤도 내 180° 위상차로 운영 중에 있다. SuperView 3호, 4호는 2018년에 발사하였으며, 위성 한기당 중량은 약 560kg이다. 관측폭(12km), 해상도(흑백 0.5m) 등 탑재체의 주요성능이 국토위성과 가장 유사한 위성으로 위성 4기 활용 시 하루에 약 90만㎢ 이상을 촬영할 수 있다(OSCAR 2021.6.18.).

다) ASNARO-1

ASNARO는 2008년 USEF(Institute for Unmanned Space Experiment Free Flyer)에서 기획한 프로젝트로 일본 NEC 회사에서 제작한 위성이다. 위성 개발 시 위성 본체에 대한 표준 플랫폼을 제작하고 필요한 용도별 탑재체를 탑재하는 것으로 국내 차세대중형위성시리즈와 동일한 형태의 위성이다. 현재 총 2기(1호 광학, 2호 SAR)의 위성이 발사되었으며, ASNARO 1호의 경우 495kg으로 0.5m(흑백) 급의 해상도를 가지며, 총 6개의 MS 밴드를 탑재하고 있다. 관측폭은 10km로 스트립, 스팟, 스테레오 촬영이 가능하다(eoPortal Dictionary, OSCAR, 2021.6.18.).

라) WorldView-Legion

WorldView 위성 시리즈 개발사인 Maxar는 WorldView-4 개발 이후 대형위성 대신 위성의 개발비용을 줄이고 지구관측 주기를 늘이기 위해 2017년 부터 약 600kg의 중형위성 급인

WorldView-Legion 개발에 착수해 2022년 발사를 앞두고 있다. WorldView-Legion은 총 6기로 2022년 두 번(2기, 4기)에 나누어 위성을 발사할 예정이다. WorldView-Legion의 해상도는 0.3m(흑백)이며, 총 8개의 MS 밴드를 탑재하고 있다. 관측폭은 9km로 6기의 위성을 태양 동기궤도와 중경사궤도를 혼합하여 운영할 예정으로, 6기 운영 시 하루 300만 ㎢ 촬영이 가능하고, 동일 지점을 하루 최대 15회를 촬영할 수 있다(eoPortal Dictionary, Maxar, 2021.11.16.). WorldView-Legion은 발사 후 간단한 센서보정, 방사보정이 된 Basic Product(Level 1B), Standard product(Level2A/2B), Otho product(Level3) 등의 산출물을 제공할 예정이다.

마) KhalifaSat

KhalifaSat은 UAE DubaiSat 시리즈의 후속위성으로 DubaiSat과 마찬가지로 한국의 기술 지원을 받아 만든 UAE 최초의 서브미터급 위성이다. 2018년 10월에 발사한 KhalifaSat은 약 330kg의 중형위성으로 해상도는 흑백 0.75m(컬러 3m), 관측폭은 12km로, 스트립, 스팟, 스테레오 촬영이 가능하다(OSCAR 2021.6.18.).

<표 12-3> DMC-3, SuperView, ASNARO-1, WorldView-Legion 위성 비교

구분		DMC-3	SuperView	ASNARO-1	WorldView-Legion
발사일		2015.07.10.	2016.12.28.(1/2호) 2018.01.09.(3/4호)	2014.11.06	2022년 예정
임무수명		7년 이상	8년 이상	3년 이상	10년 이상
중량		447kg	560kg	495kg	약 625kg
임무궤도		644.3~668.8km (태양동기궤도)	516.3~537.3km (태양동기궤도)	512.6~515.8km (태양동기궤도)	450km (태양동기, 중경사)
위성 통과 시간 (지방시)		오전 10시 30분	오전 10시 30분	오전 11시 30분	-
관측폭		23km	12km	10km	9km
FOR (Field Of Regard)		1,300km	800km	900km	-
지상 해상도	PAN	0.8m	0.5m	0.5m	0.3m
	MS	3.2m	2.0m	2.0m	1.2m
파장 대역	PAN	450~650 nm	450~890 nm	-	450~800 nm
	MS	440~910nm (4bands)	440~890nm (4bands)	- (6bands)	400~895nm (6bands)
관측운영모드		스트립(Strip imaging), 스팟(Spot imaging), 스테레오(stereo imaging)			
측위정밀도(CE90) (Without GCP)		50m 이내	9.5m 이내	-	5m

나. 고해상도 SAR 위성 개발 및 운영 현황

1) TerraSAR-X

TerraSAR-X는 독일 DLR (German Aerospace Center) 주관으로 2007년에 발사된 고해상도 SAR 위성으로 X-band data(HH/VV/HV/VH 편파) 취득을 통해 재난 및 환경모니터링, 지질, 수문, 기상 등에 활용하고 있다. 2010년 고해상도 DEM인 World DEM 생성을 위해 Pair 위성인 TanDEM-X를 발사하여 운영중이다. TanDEM-X는 TerraSAR-X 76km 뒤에서 운행되며, 위성 궤도 간의 수직거리를 최소한으로 조절해 측정 정확도를 향상시켰다(eoPortal Dictionary 2021.11.16.). 또한 DLR은 위성의 임무종료 시기를 감안하여 2024년 발사를 목적으로 TanDEM-L 위성을 개발 중에 있다. TerraSAR-X는 촬영 모드에 따라 1~16m의 공간해상도를 제공하며, 이에 따라 관측 폭도 10~100km 까지 다양하게 제공하고 있다(eoPortal Dictionary 2021.8.27., OSCAR 2021.8.27.).

2) RADARSAT Constellation

RADARSAT 위성은 캐나다의 Canada's RADARSAT Program으로 개발된 것으로 1995년 RADARSAT 1호 개발을 시작으로, 2007년 RADARSAT-2를 개발해 현재까지 운영 중이며, 업무의 연속성을 위해 2019년 RADARSAT-Constellation(3기)을 발사하고 운영 중에 있다. RADARSAT-Constellation은 C-Band data(HH/VV/HV/VH 편파) 취득을 통해 재난관리, 농경지, 습지, 숲, 수계 등의 용도로 활용하고 있다. 촬영모드에 따른 해상도는 3~100m로, 촬영 모드 별 20~500km의 관측폭을 제공할 수 있다(eoPortal Dictionary 2021.8.27., OSCAR 2021.8.27.).

3) COSMO-SkyMed Second Generation(CGS)

COSMO-SkyMed 시리즈 위성은 이탈리아 ASI (Agenzia Spaziale Italiana)에서 주관으로 1세대 위성 총 4기를 2007~2010년 까지 발사하여 현재 운영하고 있다. 이후 2019년 임무의 연속적인 수행을 위해 2세대 위성 1기를 발사 성공하였으며, 2세대 위성도 총 4기를 발사·운영할 계획이다. COSMO-SkyMed 2세대는 X-Band data(HH/VV/HV/VH 편파) 기반의 데이터를 취득하며, 촬영모드에 따라 0.35~40m의 공간해상도와 3.1~200km의 관측폭을 제공한다(eoPortal Dictionary 2021.8.27., OSCAR 2021.8.27.).

<표 12-4> TerraSAR-X, RADARSAT Constellation, CGS 위성 비교

구분	TerraSAR-X (TanDEM-X)	RADARSAT Constellation	CGS
발사일	2007.6.15. (2010.0.21.)	2019.6.12	2019.12.18
임무수명	5년 이상	7년 이상	7년 이상
중량	1,230kg (1,340kg)	1,460kg	2,205kg
임무궤도	505~533km (태양동기궤도)	586~615km (태양동기궤도)	628.7~630.7km (태양동기궤도)
위성 통과 시간 (지방시)	오전 6시	오전 6시	오전 6시
해상도	1m (Spotlight) 2m (Strip) 16m (ScanSAR)	3m (Very High Resolution) 5m (High Resolution) 16m (Medium Resolution) 30m (Medium Resolution) 50m (Medium Resolution) 100m (Low resolution)	0.35m (Spotlight 2A) 0.63m (Spotlight 2B) 0.8m (Spotlight 2C) 3m (Stripmap) 3m (Stripmap Quadpol) 20m (ScanSAR) 40m (ScanSAR)
관측폭	10~100km	20~500km	3.1~200km
FOR (Field Of Regard)	287~926km	700~1,000km	1,200km
파장대역	X-Band, 9.65 GHz(50 - 300 MHz)	C-Band, 5.405 GHz(100 MHz)	X-Band, 9.6 GHz
편파	Single : HH/VV/HV/VH	Single : HH/VV/HV/VH	Single : HH/VV/HV/VH Double: HH & HV or VV & VH Quadruple: HH & VV & HV & VH

다. 시사점

현재 고해상도 위성들은 지표 관측, 재난 모니터링 등 다양한 분야에서 지속적인 수요 증가로 미국, 유럽을 비롯한 위성개발 선도국 외에도 다양한 국가와 민간 기업들이 위성개발에 투자를 지속적으로 확대할 것으로 예측된다. 또한 기술의 고도화와 위성의 개발·발사·운영비용의 감소로 인해 위성활용의 시장규모는 더욱 더 커질 것으로 예측된다. 1999년 세계 최초 민간 활용을 위한 1m 이하의 IKONOS-2 발사의 성공 이후 주요 국가들의 위성개발은 공간해상도, 관측폭 등의 위성 성능향상, 광학센서 외에 다양한 멀티센서 탑재, 군집위성 운영, 중형위성 및 소형위성의 활용 증가를

위해 많은 투자를 진행하였다.

우선 해외 주요 위성 보유 국가와 기업들은 더 정밀하고, 효율적인 지구관측을 위해 고해상도 위성의 성능을 지속적으로 향상시켜왔다. 그 결과 2000년대 초반 0.7~1m(흑백 기준) 수준의 공간해상도를 2000년대 후반 0.5m 이하의 공간해상도로 향상시켰으며, 현재는 0.3m 내외 수준의 초고해상도 위성영상을 제공하고 있다. 2003년 NGA (National Geospatial-Intelligence Agency) 에서 NextView 프로그램으로 개발된 WorldView-3의 경우 0.31m 공간해상도의 영상을 제공하고 있으며, 올해 발사된 Airbus 사의 Pleiades-NEO도 0.3m 해상도의 위성영상을 제공한다. 인도 ISRO(Indian Space Research Organization)에서 개발한 Cartosat-3 위성은 0.28m의 해상도를 제공하고 있다. 우리나라 역시 현재 국토위성의 0.5m 수준보다 뛰어난 0.3m 수준의 공간해상도를 갖는 다목적실용위성 7호를 개발 중에 있으며, 향후 국내외에서는 지속적으로 해상도 향상을 위한 연구를 진행할 것으로 예측된다. 또한, 일부 고해상도 위성은 공간해상도는 0.7~1m 수준을 유지하면서 더 넓은 면적을 관측하기 위해 관측 폭을 증가시키고 있다. 1999년 개발된 IKONOS-2의 관측폭은 약 11km 수준에 불과했으나, 2011년 프랑스 CNES에서 발사한 Pleiades-HR의 경우, 관측폭은 20km로 약 두 배 가까이 증가하였고, 2016년 러시아에서 발사한 Resurs-P-3 위성은 관측폭을 38km까지 증가시켰다. 또한, 현재 일본 JAXA에서 개발 중인 ALOS-3 위성의 경우 0.8m의 해상도로 약 70km의 관측폭을 갖는 위성영상을 제공할 예정이다.

현재 위성들은 과거 고해상도 광학 센서만을 탑재하던 것에서 더 나아가 다양한 센서를 탑재하고 있다. WorldView-3의 경우, 산불 등의 탐지가 가능한 SWIR 8bands(해상도 3.7m)와 에어로졸, 구름, 수계 등을 탐지 할 수 있는 CAVIS 12Bands(해상도 30m) 등의 이용하여 영상을 촬영할 수 있다. 러시아의 Resurs-P 위성은 고해상도(1m 급) 외에 중해상도, 저해상도, 초분광(Hyperspectral) 센서를 탑재해 상황에 맞는 다양한 영상을 촬영하여 제공할 수 있다.

위성개발 비용의 감소, 수요 증가로 인해 위성은 과거 1기의 단일 위성 운영 형태에서 나아가 여러 대의 위성을 동시에 발사해 군집형태로 운영하고 있다. 이 경우 고해상도 위성의 좁은 촬영폭과 긴 재방문 주기 등의 단점을 보완할 수 있다. 미국 WorldView 시리즈, 프랑스 Pleiades 시리즈, 중국 GaoFen 시리즈, SuperView, DMC-3, RADARSAT Constellation, COSMO-SkyMed 등의 위성들이 같은 규격의 위성을 여러 대 제작해 군집으로 운영 중에 있다. 또한, 위성 개발비용의 감소를 위해 대형위성 대신 중형위성에 대한 수요와 활용이 지속적으로 증가하고 있다. 영국 SSTL(Surrey Satellite Technology Ltd.)에서 2015년 발사한 450kg급 중형위성 DMC-3는 총 3대가 동일 궤도상에서 일정한 간격으로 운용되고 있으며, 중국 민간 기업인 Beijing Space View Technology는 560kg 급 중형위성 위성 SuperView 4기를 개발하고 2기를 한 쌍으로 구성해 같

은 궤도에서 180° 간격으로 운영 중에 있다. 또한 WorldView 위성을 개발한 미국 Maxar는 위성으로부터 영상획득 주기 단축을 위해 2017년 WorldView-Legion이라는 약 600kg급 중형위성 6기 개발에 착수해 현재 개발 중에 있다. WorldView-Legion은 태양동기궤도 4기, 적도궤도 2기로 구성되어 매일 지구 전 지역을 관측할 수 있다.

이와 더불어 소형위성의 발사 및 활용도 지속적으로 증가하고 있다. PlanetScope, SkySat 등의 소형광학위성의 발사와 활용이 지속적으로 증가하고 있으며, SAR 위성 역시 ICEYE, Capella X-SAR, NovaSAR-S, MicroX-SAR, Umbra-SAR, iQPS-SAR, Strix α , PredaSAR 등의 위성 개발이 이루어지고 있다. 소형위성의 등장은 개발, 운영비 감소, 위성정보의 접근성 향상, 영상 활용 산업 활성화 등 위성분야에 새로운 패러다임으로 자리 잡았으며, 전 세계적으로 소형위성의 개발과 활용은 빠르게 확산될 전망이다(김윤지와 강기목, 2021).

4. 결론

국토위성은 공공수요 충족을 목적으로 개발된 국내 최초의 중형위성으로 한반도, 해외 주요 지역 등 다양한 지역을 촬영해 정밀 국토관측정보를 제공할 예정이다. 그동안 공간정보 구축의 일환으로 위성정보를 활용하긴 했지만, 위성 개발 경험이 전무 했던 국토교통부는 위성의 개발 및 기획 과정에서 미처 고려하지 못했던 부분들이 있었다. 현재 국토위성센터에서는 2021년 3월 국토위성의 성공적인 발사 이후, 공백 없는 위성정보 활용을 위해 후속위성 도입을 위한 기획연구를 추진 중에 있다. 본 보고서에서는 국토위성 기획·개발 과정에서 활용부처가 고려하지 못했던 주요 사안들에 대해 분석하였고 주요 해외 위성들의 개발·운영 현황을 조사하였다.

우선, 국토위성 개발 과정에서는 활용 목적이 명확하지 못했다. 당초 기획단계에서 국토위성은 1m의 공간해상도로 1:25,000 지도제작을 목적으로 기획되었다. 예비타당성 조사를 거치며 공간해상도를 0.5m로 상향하였다. 2014년 예비타당성 조사 당시 0.55m급의 K3A 개발이 완료 단계로 실제로 국토위성 역시 K3A 수준의 위성 개발이 가능했음에도, 위성 성능에 대한 도전적인 목표 설정이 이루어지지 못했다. 또한 활용측면에서도 위성의 역할이 명확하지 못했다. 2014년에 국토지리정보원에서 25cm의 항공영상을 2년 단위로 촬영을 진행하고 있었으며, 항공영상과 위성영상의 차별성 등을 분석하여 국토위성만의 고유 업무영역을 발굴하고 이를 수행하기 위한 위성 개발이 고려되었어야 하는데, 이에 대한 분석이 부족했다. 향후 후속위성 개발 시에는 항공영상, 드론 등 다양한 국토관측 체계를 고려하고 국토위성을 운영하며 다양한 활용분야를 발굴해 국토위성이 할 수 있는 고유업무 영역에 대한 명확한 제시가 필요하다.

국토위성 개발과정에서는 위성의 성능적인 부분에 집중한 나머지, 활용부처의 위성 활용을 위

한 의견 반영이 제한적이었다. 국토위성 1호, 2호 사용자요구사항 정의 단계에서는 국토위성이 지도제작을 위해 주로 스트리프 촬영을 진행함에도 불구하고 촬영 범위에 대한 정확한 정의가 부족했고, 스트리프 촬영 데이터를 저장하기 위한 용량, 촬영영상 전송 속도, 영상의 측위정밀도 등에 대한 검토가 부족했다. 또한, 긴급상황에서의 촬영·수신 및 위성정보의 품질관리를 위해 필요한 위성 영상 직수신 시스템을 중복투자 등의 사유로 하지 못한 것도 반영되지 못하였다. 향후 후속위성 도입 단계에서는 위성의 성능적인 검토와 더불어 활용목적에 맞는 요구사항들과 위성활용을 위해 필요한 인프라에 대해서도 면밀한 준비와 분석이 필요하다.

현재 국토위성은 위성의 기능 및 성능적인 측면에서 다목적실용위성 3A호와 유사하다. 국토위성 기획 당시 예비타당성 조사에서도 기능 및 성능 외에 지표관측, 재난 등 일부 임무가 중복으로 검토되었다. 정부에서는 다목적실용위성 3A호 보다 공간해상도가 훨씬 더 좋은 0.3m급의 다목적 실용위성 7호를 개발 중에 있다. 향후 국토위성센터에서 후속위성 도입 시에는 다목적실용위성과의 차별성에 대한 부분도 고려해야 한다. 전 세계 위성개발 국가 및 기업은 대형위성 개발·발사를 통한 위성의 정밀도(해상도)·관측 폭 향상, 중·소형 위성 개발을 통한 군집운영 및 재방문 주기 단축, 위성 내 다양한 탑재체 및 센서 탑재 등 다양한 형태로 위성을 개발하고 있다. 후속위성 역시 해상도 향상을 고려함과 동시에 다양한 센서 탑재를 통한 취득정보 증가, 관측폭 향상, 위성 동시 운영 수 증가 등을 통한 국토정보 취득 주기 단축 등 효율적인 위성정보 수집·제공을 위한 다양한 전략을 수립이 필요하다.

참고문헌

- 국토교통부 (2013). 미래 성장동력 확보를 위한 공간정보 위성 탑재체 개발 기획보고서 (2013-도시건축기획-A03).
- 교육과학기술부 (2012). 차세대중형위성 개발방향 및 전략에 관한 기획연구 (TRKO201300032599).
- 김윤지, & 강기목. (2021). 선박탐지를 위한 초소형 SAR 군집위성 활용방안 연구, 대한원격탐사학회지, 37(3), 627-636.
- 김은정. (2018). 세계 지구관측 위성 시장 현황 및 전망. 항공우주산업기술동향, 16(1), 22-29.
- 미래창조과학부 (2014). 차세대중형위성개발 선행연구 (2012M1A3A4A0105613).
- 한국과학기술기획평가원 (2014). 2013년도 예비타당성 조사 보고서 차세대 중형위성 개발사업
- Euroconsult (2020). Market Brief: Earth Observation

【전자자료】 사이트명. 인터넷주소 (검색 연월일)

- AirBus Defence & Space [website],
<https://www.intelligence-airbusds.com/imagery/constellation/pleiades-neo/>
(2021.11.16.).
- eoPortal Dictionary[website],
<https://directory.eoportal.org/web/eoportal/satellite-missions/v-w-x-y-z/worldview-2> (2021.5.7.).
- eoPortal Dictionary[website]
<https://directory.eoportal.org/web/eoportal/satellite-missions/v-w-x-y-z/worldview-3> (2021.5.7.).
- eoPortal Dictionary[website],
<https://directory.eoportal.org/web/eoportal/satellite-missions/satellite-missions/p/pleiades> (2021.5.18.).
- eoPortal Dictionary[website],
<https://directory.eoportal.org/web/eoportal/satellite-missions/p/pleiades-neo>

(2021.5.18.).

eoPortal Dictionary[website],

<https://directory.eoportal.org/web/eoportal/satellite-missions/g/gokturk-1>

(2021.6.18.).

eoPortal Dictionary[website],

<https://directory.eoportal.org/web/eoportal/satellite-missions/d/dmc-3>

(2021.6.18.).

eoPortal Dictionary[website],

<https://eoportal.org/web/eoportal/satellite-missions/t/terrasar-x> (2021.8.27.).

eoPortal Dictionary[website],

<https://directory.eoportal.org/web/eoportal/satellite-missions/r/rcm>

(2021.8.27.).

eoPortal Dictionary[website],

<https://directory.eoportal.org/web/eoportal/satellite-missions/c-missions/cosmo-skymed-second-generation> (2021.8.27.).

eoPortal Dictionary[website],

<https://eoportal.org/web/eoportal/satellite-missions/t/tandem-x>

(2021.11.16.).

eoPortal Dictionary[website],

<https://directory.eoportal.org/web/eoportal/satellite-missions/v-w-x-y-z/worldview-legion> (2021.11.16.).

Innoter[website], <https://innoter.com/en/satellites/resurs-p-1-2-3/> (2021.5.18.).

JAXA[website], https://www.eorc.jaxa.jp/ALOS/en/ALOS-3/ALOS-3_top.htm,
(2021.6.18.).

Maxar[website], <https://www.maxar.com/splash/it-takes-a-legion> (2021.11.16.).

N2YO[website], <https://www.n2yo.com/satellite/?s=35946> (2021.5.7.).

N2YO[website], <https://www.n2yo.com/satellite/?s=40115> (2021.5.7.).

OSCAR[website], https://space.oscar.wmo.int/satellites/view/gokturk_1a
(2021.6.18.).

OSCAR[website], <https://space.oscar.wmo.int/satellites/view/gf> (2021.6.18.).

OSCAR[website], https://space.oscar.wmo.int/satellites/view/gf_7 (2021.6.18.).

OSCAR[website], https://space.oscar.wmo.int/instruments/view/pan_cartosat_3
(2021.6.18.).

OSCAR[website], https://space.oscar.wmo.int/instruments/view/pms_3
(2021.6.18.).

OSCAR[website], https://space.oscar.wmo.int/satellites/view/dubaisat_3
(2021.6.18.).

OSCAR[website], https://space.oscar.wmo.int/satellites/view/terrasar_x
(2021.8.27.).

OSCAR[website], https://space.oscar.wmo.int/satellites/view/rcm_1 (2021.8.27.).

OSCAR[website], https://space.oscar.wmo.int/satellites/view/csg_1 (2021.8.27.).

UCS Satellite database[website],
<https://www.ucsusa.org/resources/satellite-database> (2021.5.7.).

주 의 사 항

1. 본 보고서는 국토교통부 국토지리정보원 국토위성센터에서 발행한 연구보고서입니다.
2. 본 내용을 대외적으로 게재, 인용할 때에는 반드시 국토교통부 국토지리정보원의 사전 허락을 받기 바라며, 무단 복제는 절대 금합니다.

국토위성센터 연구보고서

인쇄·2021년 12월

발행·2021년 12월

발행처·국토교통부 국토지리정보원

주소·경기도 수원시 영통구 월드컵로 92(원천동)

전화·031-210-2700

FAX·031-210-2644