

Sentinel-2 시계열 영상을 활용한 토지피복변화 모니터링

The Monitoring of Land Cover Changes Using Time-Series Images of Sentinel-2

정종철 Jeong, Jong Chul*

Abstract

This paper presents a comparison of time-series land cover changes from Sentinel-2 imagery from 2017 to 2018 using machine learning. For the machine learning point sampling, we collected approximately 3% of the total pixels at an identical 250 points per class, referring to a digital land cover map of EGIS. To compare land cover changes, the SVM(Support Vector Machine) model was used. The results of time series analysis shows that areas of wetland and bare soil increased, agricultural and grass decreased, and the areas of built-up, forest, and water did not change significantly over the two years. The monthly f1-score remained between 0.61 and 0.67 and the f1-score in April was the highest. When accuracy verification was performed using the error matrix, water areas showed the highest accuracy. Classes that mainly occur in the context of vegetation activity were often misclassified, and built-up areas were found to be misclassified with classes that see vegetation activity due to seasonal effects. The characteristics of each class were confirmed using variable importance. On average, R, G, B, and NDVI showed high importance values regardless of seasonal conditions, but NIR, SWIR, and Red Edge bands were seasonally affected. Additional studies are expected to improve accuracy by considering the number of samples relative to the class area, the selection of training areas and the selection of indices.

Keywords: Land Cover Change, Sentinel-2, SVM, Variable Importance

I. 서론

토지이용변화 모니터링은 주기적으로 토지의 상태를 파악하며 토지이용이나 피복의 변화를 탐지하고 변화를 예측하는 활동이다. 그중 토지피복분류는 토지의 현황 파악에 목적을 두고 있다. 토지피복도는 촬영 시기의 토지 특성을 나타내며, 이 자료는 다양한 정책의 기초자료가 된다(서기환, 오창화, 김다윗, 이민영 외

2018; 김성희, 김동근 2020; 박현수, 장동호 2020). 따라서 토지피복 모니터링을 하기 위해서는 정확한 토지의 속성 정보가 필요하다.

환경부는 1998년부터 대분류, 중분류, 세분류 토지 피복도를 제작·배포하고 있다. 대분류 토지피복도는 Landsat-TM(해상도 30m) 위성영상을 이용하여 2010년대 말까지 제작·배포되었다. 중분류 토지피복도는 2000년대부터 수도권을 시작으로 2013년도까지 전국

* 남서울대학교 드론공간정보공학과 교수 | Professor, Department of Drone Geographic Information Science, NamSeoul University | jjc1017@gmail.com

적으로 Landsat-TM, 아리랑위성과 항공영상 등을 이용하여 해상도 5m급으로 제작·배포되었다. 세분류 토지피복도의 경우, 2010년부터 2023년까지 아리랑위성과 항공영상을 이용하여 해상도 1m급으로 권역별로 제작되었고 환경부는 2019년과 2020년 2차례 세분류 토지피복도 전국 현행화 구축을 시행하였다(환경공간정보서비스, <https://egis.me.go.kr/info/land.do>).

하지만 토지이용변화 모니터링을 위한 토지피복도의 사용에는 문제점이 존재한다. 대분류 토지피복도는 갱신주기가 길며 권역별로 제작된 토지피복도는 제작기간이 서로 맞지 않고 중분류와 세분류의 경우 같은 지역의 구축시기가 서로 달라서 적절한 토지피복 정보를 제공하지 못하는 한계가 존재한다(조원호, 임용호, 박기호 2019).

이런 문제를 해결하기 위해 원격탐사 분야에서 인공지능기술을 이용하여 균일하고 갱신이 빠른 토지피복분류 연구가 활발히 진행되고 있다(강남이, 고신영, 조기성 2013; 송지용, 정종철, 이상훈 2018; 김준, 송용호, 이우균 2021; Acharya, Yang and Lee 2016).

Abdi(2020)는 Sentinel-2 자료와 인공지능 알고리즘을 이용하여 시계열 영상을 분석하였다. 이 연구는 초평면을 결정하는 인자의 수가 적은 이유로 SVM(Support Vector Machine) 알고리즘이 가장 높은 정확도를 보여 주었으며 SWIR과 Red Edge 밴드, 그리고 5월, 7월 영상이 분석에 큰 영향력을 행사함을 발견하였다.

He and Garcia(2009)는 불균형 데이터는 OA(Overall Accuracy)를 왜곡시킨다고 하였다. 하지만 Abdi(2020)와 Olofsson, Foody, Herold and Stehman et al.(2014)은 면적 비율을 고려하지 않으면 OA가 낮아질 수 있다고 하였고 특정 클래스가 잘 표현된 불균형 데이터를 사용하면 더 높은 OA를 얻을 수 있다고 하였다.

정확하고 빠른 갱신주기를 가지는 토지피복도를 제작하기 위해서 여러 방법이 연구되고 있지만 Sentinel-2

는 공간해상도와 시간해상도가 Landsat-8보다 우수하며 접근성도 좋다(장순신 2018). 그러한 이유로 다양한 분야에서 Sentinel 영상을 이용한 연구가 진행되고 있다(김란희, 김현우, 이재희, 이승훈 2016; 조기환, 정종철 2018). Sentinel-2 영상으로 국내 토지피복분류 시계열 분석을 수행한 연구는 다양한 분석 기술의 적용이 필요하고 머신러닝 기법을 적용할 시 발생할 문제점을 분석한 사례를 국내 토지피복도에 적용할 필요성이 있다.

따라서 본 연구는 효율적이고 정확한 시계열 토지피복변화 모니터링을 위해 머신러닝 기술을 사용하여 시계열 토지피복분류 결과를 환경공간정보서비스의 세분류 토지피복도와 비교하였다. 그리고 오차행렬을 이용한 정확도 검증, 변수 중요도를 활용하여 식물계절적 영향 등을 판단하는 데 연구의 목적이 있다.

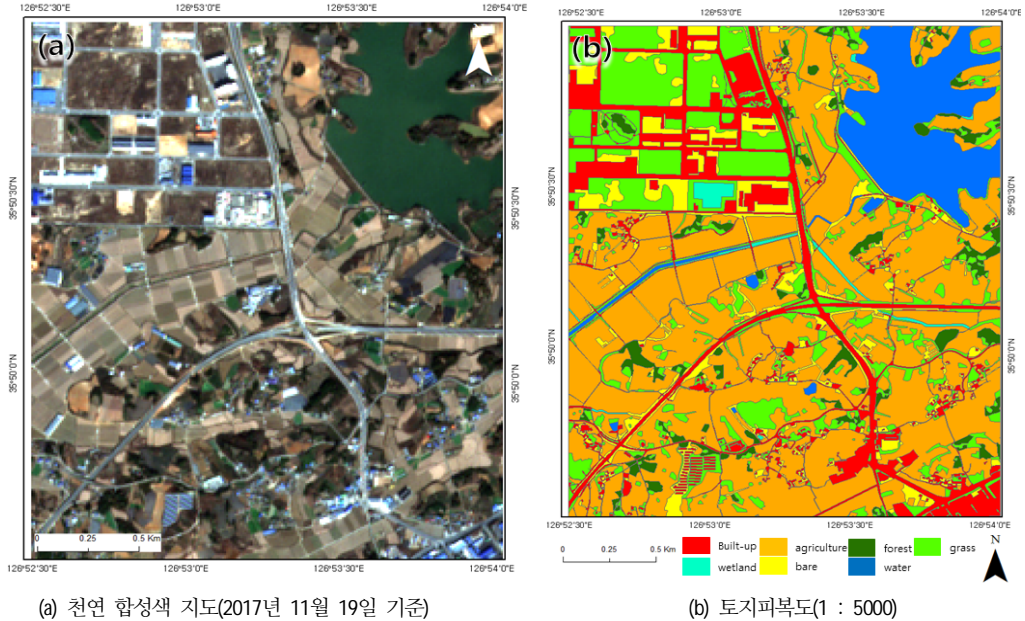
II. 연구 방법

1. 연구 대상지 및 사용 데이터

본 연구지역 대상지는 전라북도 김제시 백산면 일대이며 지리적 위치는 북경 35° 50′ 동경 126° 52′ ~ 126° 54′ 에 위치하고 있다. 백산면의 지형적 위치는 평지 고원 지대이며 산업단지, 저수지, 야산, 논 등을 포함하는 지역으로 산업단지가 위치해 있다. 계절적 분광 특성이 잘 나타나는 농경지는 경작으로 인해 토지이용 변화가 매우 활발한 지역이기 때문에 이곳을 대상으로 선정하였다.

훈련지역의 총면적은 656.6ha이며 피복분류를 위해 시가화지역, 농경지, 산림, 초지, 습지, 나지, 수역 총 7개 항목으로 구분하였다. 환경부 토지피복도 기준으로 각 항목당 면적은 시가화지역 92.7ha, 농경지 309.7ha, 산림 23.3ha, 초지 117.0ha, 습지 5.0ha, 나지 48.1ha, 수역 60.8ha이다. <그림 1>은 연구 대상지를

그림 1 _ Sentinel-2호 위성영상으로 관측한 김제 연구 지역



나타낸다. 연구에 사용된 자료는 2017년 2월 2일부터 2018년 1월 3일까지 총 9장의 L1C Sentinel-2A-B 시계열 영상 데이터를 사용하였다. Sentinel-2 위성은 다중 분광센서를 탑재하고 있고 특히 20m의 Red Edge 밴

드와 20m의 SWIR 밴드를 가지고 있다. 피복분류분석을 위해 사용한 밴드는 SWIR, NIR, Red Edge, RGB 영상이며, <표 1>은 Sentinel-2A-B 영상 제원을 나타낸다.

표 1 _ Sentinel 2A호와 2B호의 특성과 수집된 날짜

Band No.	Band Name	Central Wavelength(nm)		Spatial Resolution(m)	Acquisition Date
		2A	2B		
1	Coastal Aerosol	442.7	442.2	60	2017. 2. 2. 14:24:15 2017. 3. 4. 14:23:31 2017. 4. 13. 14:23:47 2017. 5. 3. 14:23:50 2017. 8. 31. 14:23:48 2017. 10. 30. 14:26:23 2017. 11. 14. 14:19:25 2017. 11. 19. 14:23:41 2018. 1. 3. 14:21:46
2	Blue	492.4	492.1	10	
3	Green	559.8	559.0	10	
4	Red	664.6	664.9	10	
5	Vegetation Red Edge	704.1	703.8	20	
6	Vegetation Red Edge	740.5	739.1	20	
7	Vegetation Red Edge	782.8	779.7	20	
8	NIR	832.8	832.9	10	
8A	Vegetation Red Edge	864.7	832.9	20	
9	Water Vapor	945.1	943.2	60	
10	Cirrus	1373.5	1376.9	60	
11	Shortwave Infrared	1613.7	1610.4	20	
12	Shortwave Infrared	2202.4	2185.7	20	

2. 활용 알고리즘

본 연구에서는 NDVI, MNDWI, NDBI 지수식과 SVM 기법을 이용하여 토지피복분류 분석을 진행하였다.

1) NDVI(Normalized Difference Vegetation Index)

정규식생지수는 Rouse, Haas, Schell and Deering(1974)가 고안한 지수식으로 적색 밴드와 근적외선 밴드를 이용하여 식생활동을 알 수 있으며 식생구분에 중요하게 활용되는 지수이다(<식 1> 참조). 일반적으로 값은 -1에서 1까지 분포되는데 1에 가까울수록 식생활동이 활발하고 비식생지역에서는 -1에서 0까지 분포한다.

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad <식 1>$$

2) MNDWI(Modified Normalized Difference Water Index)

수정정규수분지수는 Xu(2006)가 정규수분지수(NDWI)를 보정한 <식 2>로 기존 NIR 밴드보다 MIR 밴드에서 명확한 수역을 구분하는 장점이 있다. 본 연구는 Landsat ETM+ MIR 영역대와 비슷한 Sentinel-2 Band 12를 사용하였다(Du, Zhang, Ling and Wang et al. 2016).

$$MNDWI = \frac{GREEN - MIR}{GREEN + MIR} \quad <식 2>$$

3) NDBI(Normalized Difference Built-up Index)

정규시가화지수는 Zha, Gao and Ni(2003)가 효과적인 도심지 추출을 하기 위해 제안한 지수식이다(<식 3> 참조). NDBI는 나지와 도심지의 분광특성이 근적외선

의 반사도 보다 중적외선의 반사도가 높은 특징을 가지고 있다. 본 연구에서는 파장대가 비슷한 Sentinel-2 Band 11을 사용하였다(Kuc and Chormański 2019).

$$NDBI = \frac{MIR - NIR}{MIR + NIR} \quad <식 3>$$

4) SVM(Support Vector Machine)

SVM은 각 클래스 사이의 최대 마진이 발생하는 서포트 벡터를 선정하고 다차원 공간에서 최적의 초평면을 생성하여 분류하는 기계학습 기법이다(Cortes and Vapnik 1995; Maxwell, Warner and Fang 2018). SVM 파라미터는 C와 gamma 매개변수가 있으며 C는 서포트 벡터를 조절하는 인자이고 gamma는 비선형 초평면을 조정하는 인자이다. SVM 커널은 RBF(Radial Basis Function) 커널을 이용하였고 파라미터 설정은 R 소프트웨어를 이용하여 영상마다 인자들을 적용하여 분석하였다.

5) 오차행렬(Confusion Matrix)

오차행렬이란 토지피복도 분류자료와 검증자료를 활용하여 검증자료와 분류자료의 정확도를 검증하는 방법이다(이슬기, 박성재, 백경민, 김한별 외 2019). 본 연구에서는 정밀도, 재현율, f1-점수를 산출하였다. 위성영상 정확도 검증 분야에서 정밀도는 UA(User's Accuracy)와 같은 의미이고 재현율은 PA(Producer's Accuracy)와 같은 의미이다(유수홍, 이지상, 배준수, 손흥규 2020).

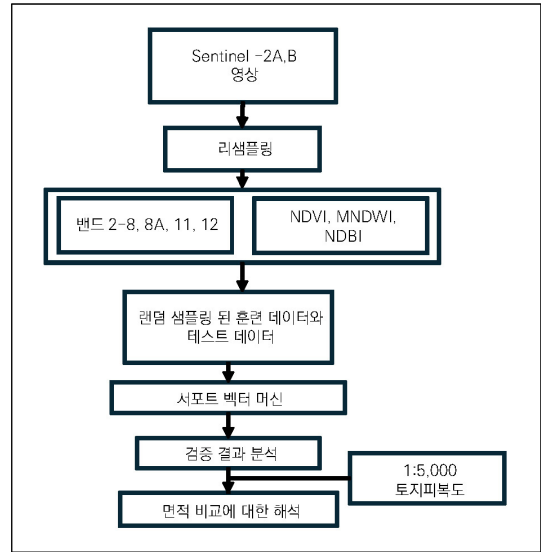
또한, f1-점수는 재현율과 정밀도에 대한 기하평균을 뜻하며 분류 결과가 불균형할 때 사용된다. 따라서 정밀도와 재현율은 Sentinel-2 영상분류의 UA와 PA로 표현하였고 f1-점수로 분류 클래스의 정확도를 판별하였다.

3. 데이터 처리

본 연구는 R 소프트웨어 3.6.3 버전을 이용하여 SVM 알고리즘으로 김제지역 토지피복변화를 분석하였다. 분석방법은 미국 지질조사국(United States Geological Survey: USGS)에서 제공하는 위성영상 다운로드 사이트에서 2017년 2월부터 2018년 1월까지 구름이 없는 총 9장의 월별 L1C Sentinel-2A/B 데이터를 수집하였다.

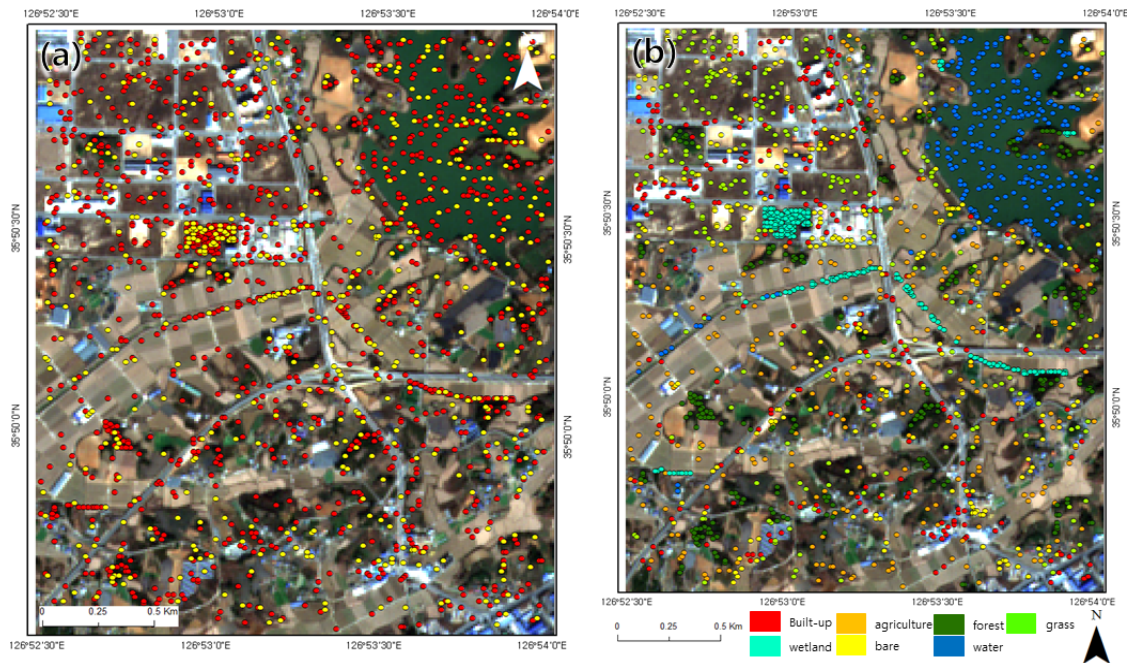
<그림 2>는 연구 흐름을 나타낸다. 전처리 과정은 유럽우주국(European Space Agency: ESA)에서 제공하는 SNAP 소프트웨어 7.0.3 버전을 이용하였다. 공간해상도는 최근린 표본 재추출법을 사용하여 10m로 리샘플링하고 훈련지역을 추출하였다. 샘플 포인트 자료를 구축하기 위해서 구글어스와 환경부에서 제공하는 세분류 토지피복도를 참조하였다. 10m 공간해상도에 맞추어 샘플 포인트 자료를 생성하였고, 랜덤

그림 2_연구 흐름도



선택하여 포인트 자료와 토지피복도의 속성을 공간 결합하였다. 토지피복변화 분석을 위한 7개 속성으로

그림 3_전체 연구지역 훈련 데이터와 평가 데이터



(a) 훈련 데이터(빨간색 점)와 평가 데이터(노란색 점)

(b) 토지피복도의 속성별 레이블링된 데이터 포인트

클래스를 지정하였다.

위성영상처리에는 ENVI 5.3 버전으로 NDVI, NDBI, MNDWI 지수를 제작하였고 랜덤포레스트(Random Forest)를 지원하는 R 소프트웨어를 이용하여 SVM 알고리즘을 구현하였다.

<그림 3>은 샘플 포인트 데이터의 분포를 나타낸다. (a)는 머신러닝 알고리즘에 사용될 훈련 데이터와 평가 데이터의 분포이다. 적색 포인트는 훈련 데이터로 1,225개, 노란색 포인트는 평가 데이터로 525개로 구성되어 있다. (b)는 (a)의 데이터를 클래스로 구분하였다. 수집한 데이터는 각 분류 항목당 면적 비율에 상관없이 동일하게 250개씩 7개 클래스로 분류하여 전체 픽셀의 약 3%(1,750개)를 랜덤샘플링하였다. 훈련지역의 픽셀 수는 232x283픽셀로 총 6만 3,656개이다.

훈련 자료와 평가 데이터는 10-fold로 구성하고 7:3

비율로 분류하였으며 5번을 반복하여 교차검증을 하였다. 분류 정확도 검증은 오차행렬을 이용하여 실측 자료(Ground Truth Points)를 검증하였고 토지피복도의 면적과 SVM 분류 결과를 비교하였다. 분류 결과에 영향을 미치는 토지피복분류 항목별 변수 중요도를 R 소프트웨어에서 제공하는 변수 중요도 함수를 이용하여 파악하였다.

III. 연구 결과

1. 모델의 평가 및 시계열 면적 변화

본 연구에서는 시계열 Sentinel-2A-B 위성영상을 SVM 분류기법을 이용하여 토지피복분류 결과를 분석하였다. 김제지역 피복분류 결과는 <표 2>, <그림 4>와

표 2 _ 토지피복 결과와 SVM 알고리즘의 정확도 평가

SVM	02/02/2017	03/04/2017	04/13/2017	05/03/2017	08/31/2017	10/30/2017	11/14/2017	11/19/2017	01/03/2018
	f1-점수=0.61 Area(ha)	f1-점수=0.62 Area(ha)	f1-점수=0.67 Area(ha)	f1-점수=0.63 Area(ha)	f1-점수=0.63 Area(ha)	f1-점수=0.63 Area(ha)	f1-점수=0.64 Area(ha)	f1-점수=0.64 Area(ha)	f1-점수=0.64 Area(ha)
시가화	86.3	83.7	88.5	82.3	87.1	111.7	107.8	85.3	85.4
PA(%)	66.7	70.7	66.7	69.3	62.7	65.3	61.3	66.7	61.3
UA(%)	75.8	71.6	70.4	73.2	66.2	57.6	59.7	69.4	73.0
농경지	215.0	216.7	213.5	197.2	158.6	195.4	195.0	195.1	193.0
PA(%)	54.7	56.0	61.3	49.3	57.3	57.3	61.3	45.3	49.3
UA(%)	40.6	37.8	55.4	45.1	58.9	51.2	47.9	45.3	43.5
산림	63.7	59.8	63.0	86.9	72.6	66.8	80.6	64.4	65.0
PA(%)	81.3	81.3	80.0	82.7	77.3	81.3	89.3	81.3	80.0
UA(%)	73.5	83.6	70.6	63.3	70.7	72.6	77.0	78.2	75.0
초지	100.7	98.7	95.8	83.0	99.3	80.6	86.0	83.7	70.9
PA(%)	49.3	41.3	48.0	38.7	46.7	41.3	45.3	48.0	41.3
UA(%)	48.1	49.2	56.3	51.8	54.7	66.0	65.4	60.0	54.4
습지	59.8	47.7	50.3	44.1	75.9	82.4	74.0	76.6	75.0
PA(%)	56.0	57.3	76.0	68.0	64.0	89.3	81.3	84.0	73.3
UA(%)	63.6	52.4	72.2	70.8	55.8	62.0	62.2	62.4	68.8
나대지	73.6	93.5	87.9	95.8	98.0	62.6	57.2	92.8	110.4
PA(%)	29.3	30.7	48.0	41.3	41.3	25.3	28.0	34.7	49.3
UA(%)	36.1	45.1	48.6	42.5	41.9	38.8	47.7	38.2	41.1
수역	57.5	56.4	57.6	67.3	65.0	57.2	56.1	58.7	56.7
PA(%)	88.0	93.3	92.0	94.7	93.3	89.3	88.0	89.3	89.3
UA(%)	93.0	98.6	100.0	97.3	93.3	98.5	93.0	94.4	95.7

같다. 토지피복도의 f1-점수는 0.61에서 0.67 사이로 나타났으며, 4월의 f1-점수가 가장 높았다. 또한 분류 항목 중 수역, 산림, 시가화지역 순으로 f1-점수가 높았다. <표 2>의 2017년 2월과 2018년 1월의 SVM의 토지피복변화를 보면, 습지(+15.2ha)와 나대지(+36.8ha)는 면적이 증가하였으나, 농경지(-22.0ha), 초지(-29.8ha)는 면적이 감소하였다.

시가화지역(-0.9ha), 산림(+1.3ha), 수역(-0.8ha)의 면적은 큰 차이를 보이지 않았다. <그림 4>는 시계열 토지피복변화를 나타낸다. 농경지의 경우, 월별 토지피복도와 비교하였을 때 과소추정된 상태이며 8월에 면적이 많이 감소하였는데 영상을 확인해 보면 농경지에서 모내기 습지의 경우, 분류면적이 58.9ha에서 75.0ha까지 점차 증가하였다. 하지만 토지피복도의 면적은 5.0ha이며 토지피복도를 참값으로 볼 때, 과대추정되었음을 추측할 수 있다. 이러한 이유는 <표 3>에서 확인할 수 있는데 데이터 입력 과정에서 농경지가 가장 많이 오분류되었고 예측 결과는 농경지뿐만 아니라 모든 분류 항목에 오분류되는 결과를 확인할 수 있었다.

가장 적은 면적을 차지하는 습지에서는 다른 분류 항목과 동일한 수의 샘플을 랜덤 수집하였기 때문에 데이터 수집에서 문제가 발생했음을 알 수 있었다. 초지의 경우, 8월을 제외하고 면적이 점차 감소하였다.

그림 4_SVM 알고리즘의 시계열 분류 변화

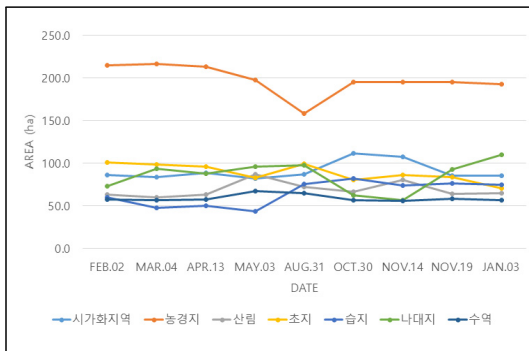


표 3_분류 결과의 오차행렬 결과 표

(단위: 포인트 수)

구분	Land Cover							합계	
	시가화 지역	농경지	산림	초지	습지	나대지	수역		
SVM	시가화 지역	49	3	1	3	1	14	0	72
	농경지	5	41	4	11	10	15	2	88
	산림	0	8	61	7	3	2	0	83
	초지	2	6	4	33	5	9	0	60
	습지	3	7	3	9	54	7	3	86
	나대지	15	8	1	11	2	27	1	65
	수역	0	2	0	1	0	0	68	71
	합계	75	75	75	75	75	75	75	525

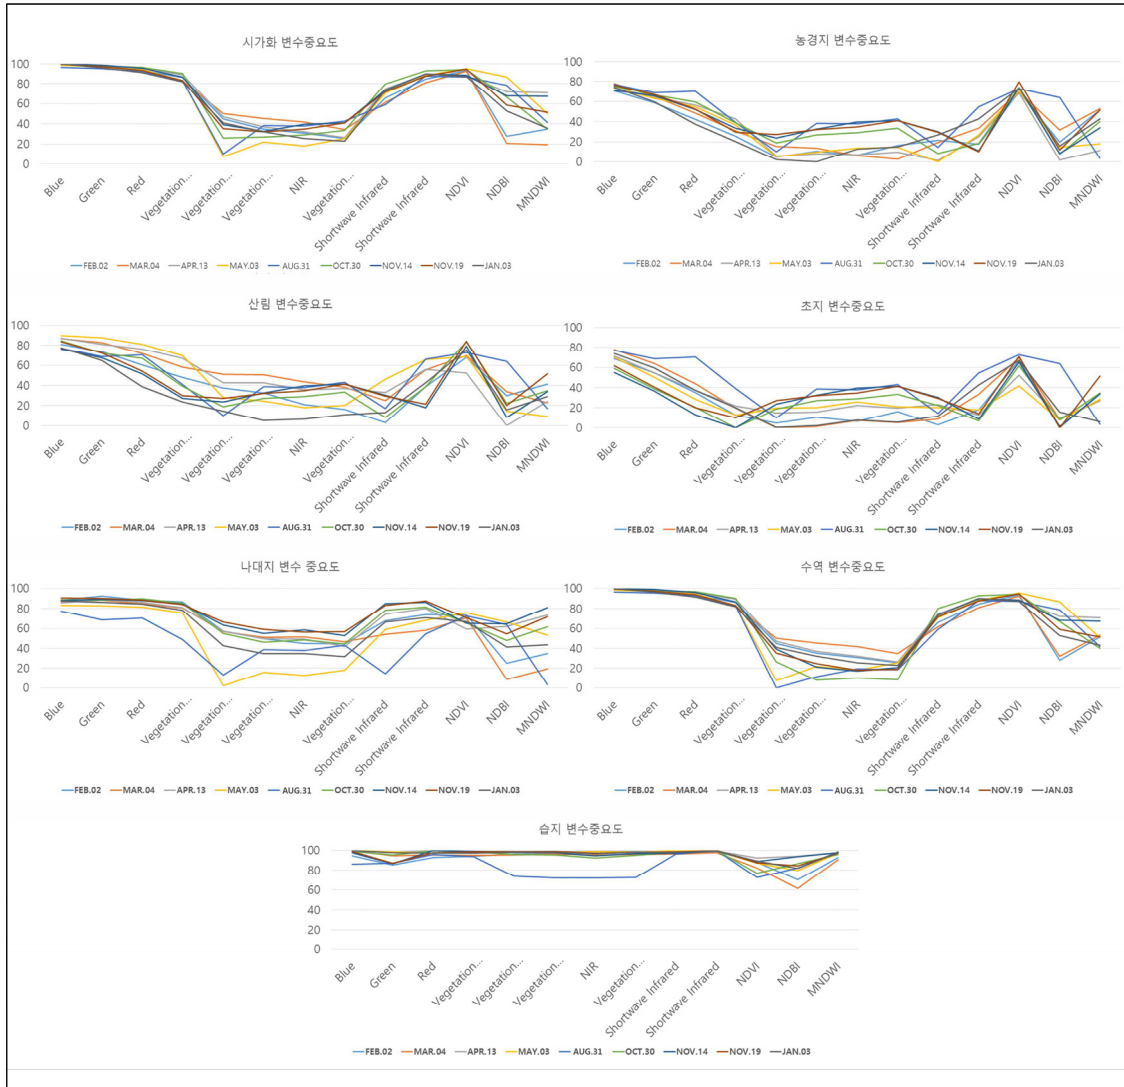
토지피복도와 비교하였을 때, 2월의 영상이 가장 유사하였다. 그러나 월별 초지의 PA와 UA는 50% 이하의 모습을 보여주었다.

또한, 예측된 초지는 농경지, 나대지, 습지에 오분류되었다. 나대지 면적의 경우 10월과 11월을 제외하고 토지피복도와 비교했을 때 과대추정되었으며 나대지 면적의 변화는 점차 증가하는 모습을 보였다. <표 3>을 보면 나대지는 주로 시가화지역, 농경지, 초지 분류 항목에 오분류가 되었다. 수역의 경우, 분류 항목 중 가장 높은 PA와 UA를 나타내고 토지피복도와 비교하였을 때 가장 유사한 면적이었다. <표 3>에서 오분류된 샘플들이 극히 적으며 월별 모두 80% 이상의 정확도를 보여 가장 우수한 결과를 보여주었다. 면적은 여름철을 제외하고 비슷한 결과가 나타났다.

2. 분류 항목별 변수 중요도

<그림 5>는 SVM 분류에 사용된 밴드를 분류 항목별로 변수 중요도를 나타낸 것이다. 유사한 흐름을 보여주는 항목은 시가화지역과 수역이었다. 시가화지역과 수역은 유사한 변수 중요도 그래프가 나타났다. 상위 5개의 밴드는 Blue, Green, Red, NDVI, Shortwave Infrared

그림 5_SVM 알고리즘의 클래스별 변수 중요도



로 80% 이상의 수치가 나타났다. 이상치로 판단되는 분류 항목은 습지이다.

습지는 토지피복도와 비교하였을 때 과대추정되었고 오차행렬 또한 오분류된 항목들이 존재하였다. 이러한 이유로 예측된 습지 항목에는 나대지, 농경지, 초지 등이 섞여 모든 밴드가 높은 변수 중요도를 나타내는 것으로 판단된다. 초지와 농경지 분류 항목도 마찬가지로 동일한 변수 중요도가 나타났다. 상위 5개 밴드는

Blue, NDVI, Green, Red, MNDWI 순으로 나타났다. 산림의 상위 중요도는 Blue, Green, NDVI, RED, Red Edge를 포함하였다. 나대지 항목의 상위밴드는 Blue, Green, RED, Vegetation Red Edge, Shortwave Infrared를 포함하였다.

식생을 포함하는 분류 항목인 초지, 산림, 농경지 분류 항목은 비슷한 추세를 보여주었다. NDVI, NDBI, MNDWI를 추가하였을 때, 가장 중요한 변수는 NDVI

였다. 가장 높은 수치를 나타냈으며 계절의 상관없이 분류 모델의 중요한 변수임을 나타내었다. NDBI는 정규시가지화지수로 시가지화지역을 구분하는 지수식이다. 분류 항목 중 시가지화 분류 항목에서 가장 우세하였지만 월마다 중요도가 변하였으며 봄과 여름에 변수 중요도가 높아지고 겨울철로 갈수록 변수 중요도가 낮아졌다. MNDWI는 수역, 나대지, 시가지화지역 분류 항목에 가장 큰 영향을 끼쳤고 공통적으로 4월 13일에 70% 이상의 수치를 나타냈다. 분류 항목이 공통적으로 열세인 밴드는 Red Edge와 NIR이다. 월마다 변수 중요도는 차이가 있지만 50% 이하를 보여주었다.

IV. 결론 및 향후 과제

본 연구는 Sentinel-2A-B와 SVM 모델을 활용하여 토지피복분류를 분석하였다. 결과는 환경공간정보서비스 토지피복도와 비교하였고 정확도 검증과 변수 중요도를 분석하여 계절적 특성과 특정 밴드 활용도를 분석하였다. 이를 통해 정확한 토지피복분류를 하기 위한 개선사항을 제시하였다.

연구 결과, 시가지화지역과 수역의 면적은 토지피복도와 유사한 면적을 나타냈으며 농경지와 초지는 과소추정되었다. 습지와 산림 그리고 나대지는 과대추정되었다. 1년간 시계열 피복 변화를 보면, 습지(+15.2ha)와 나대지(+36.8ha)는 면적이 증가하였고 농경지(-22.0ha)와 초지(-29.8ha)는 감소하였다. 시가지화지역(-0.9ha), 산림(+1.3ha) 그리고 수역(-0.8ha)의 면적은 크게 변화하지 않았다.

오차행렬을 통해 수역은 높은 정확도를 확인하였으나 습지, 농경지, 초지 등 식생활동이 주로 일어나는 분류 항목 사이에 오분류가 자주 발생하였다. 이는 포인트 샘플링할 때, 식물계절적 영향 등으로 분류 항목 사이의 오분류되는 점을 확인할 수 있었다. 또한

나대지, 시가지화지역과 초지 사이에서 오분류되는 점을 확인할 수 있었다. 산업단지 부근에서 8월의 영상을 확인하면 습지, 나대지, 초지 사이에 식생활동이 자주 일어나면서 시가지화지역이 오분류되는 것을 발견하였다.

분류 항목별 밴드 특성은 시가지화지역과 수역의 그래프는 매우 유사한 모습을 보여주었다. R, G, B, NDVI, SWIR 밴드들이 계절과 상관없이 높은 중요도를 보여주었으며 Red Edge와 NIR은 상대적으로 낮았다. 그 외 농경지, 초지, 산림 분류 항목들이 유사한 패턴을 보여주었는데 B, NDVI가 가장 높은 중요도를 보여주었으며 두 밴드는 계절에 상관없이 높은 수치를 유지하였다. 나대지는 B, G, R, Red Edge, SWIR 순으로 높은 수치를 유지하였다. 나대지와 시가지화지역의 계절적 영향은 비슷하였는데 5월과 8월에 Red Edge 밴드의 중요도가 낮아짐을 발견하였다. NDBI, MNDWI 밴드는 특정 분류 항목을 목표로 산출된 지수식이어서 항목마다 편차가 존재하였다.

전체적으로 식생이 부분적으로 존재하거나 식생이 발달하여 분광혼합되는 분류 항목들에 오분류가 자주 발생하였는데 이를 구분하기 위해 추가적으로 연구할 필요가 있다. Red Edge, NIR, SWIR은 변수 중요도가 대부분 낮게 나왔는데 이를 직접 활용하는 것보다 지수식을 개발하여 사용하는 것이 적절하다고 판단된다. 또한 연구지역과 비슷한 시기에 제작된 토지피복도를 이용하였지만 월별 달라지는 토지피복에 대해서 정확도가 떨어지는 부분을 고려하여 적절한 훈련 데이터 선정, 면적 대비 훈련 데이터 개수, 지수식 선정 등을 추가로 고려하여 학습할 때 더 높은 정확도를 보일 것으로 판단된다.

참고문헌 •••••

1. 강남이, 고신영, 조기성. 2013. KOMPSAT-2 영상의 토지피복분류에 적합한 SVM 커널 함수 비교 연구. 한국지형공간정보학회지 21권, 2호: 19-25.
Kang, Nam Yi, Go, Sin Young and Cho, Gi Sung. 2013. A comparative study on suitable SVM kernel function of land cover classification using KOMPSAT-2 imagery. *Journal of the Korean Society for Geospatial Information System* 21, no.2: 19-25.
2. 김란희, 김현우, 이재희, 이승훈. 2016. 위성자료를 이용한 북한지역 토지피복 및 식생 변화 추정. 국토연구 90권: 117-128.
Kim Ran Hui, Kim Hyun Woo, Lee Jae-Hee and Lee Seunghoon. 2016. Estimation of land cover and vegetation change in North Korea using satellite data. *The Korea Spatial Planning Review* 90: 117-128.
3. 김성희, 김동근. 2020. 비도시지역 난개발 토지이용행태 분석 기법 연구: 토지이용의 분산과 혼재를 중심으로 국토연구 105권: 145-163.
Kim Seonghee and Kim Dongkun. 2020. Analysis method of disorderly land use behavior in non-urban area: Focused on land use diffusion and mixture. *The Korea Spatial Planning Review* 105: 145-163.
4. 김준, 송용호, 이우균. 2021. U-Net 기반 딥러닝 모델을 이용한 다중시기 계절학적 토지피복 분류 정확도 분석: 서울 지역을 중심으로. 대한원격탐사학회지 37권, 3호: 409-418.
Joon Kim, Yongho Song and Woo-Kyun Lee. 2021. Accuracy analysis of multi-series phenological landcover classification using U-Net-based deep learning model: Focusing on the Seoul, Republic of Korea. *Korean Journal of Remote Sensing* 37, no.3: 409-418.
5. 박현수, 장동호. 2020. 시계열 토지피복 변화 탐지를 통한 대전광역시의 시가지지역 변화 패턴 분석: 다중시기 위성영상을 활용하여. 한국지리학회지 9권, 1호: 177-190.
Hyun-Su Park and Dong-Ho Jang. 2020. Analysis of changes in urbanized areas in Daejeon metropolitan city by detection of changes in time series landcover: Using multi-temporal satellite images. *Journal of the association of Korean geographers* 9, no.1: 177-190.
6. 서기환, 오창화, 김다윗, 이민영, 양윤정, 이은규. 2018. 지속 가능한 국토발전을 위한 토지이용변화 모니터링 방안 연구: 딥러닝 알고리즘 활용을 중심으로. 세종: 국토연구원.
Kihwan Seo, Changwha Oh, David Kim, Min-Yeong Lee, Yunjeong Yang and Eun-gyu Lee. 2018. *Monitoring Method of Land Use and Land Cover Change using Deep Learning ALgorithm*. Sejong: Korea Research Institute for Human Settlements.
7. 송지용, 정종철, 이상훈. 2018. KOMPSAT-3A 위성영상과 토지피복도를 활용한 산림식생의 임상 분류법 개발. 한국환경생태학회지 32권, 6호: 686-697.
Ji-Yong Song, Jong-Chul Jeong and Peter Sang-Hoon Lee. 2018. Development of a classification method for forest vegetation on the stand level, using KOMPSAT-3A imagery and Land coverage map. *Korean Journal of Environment and Ecology* 32, no.6: 686-697.
8. 유수홍, 이지상, 배준수, 손홍규. 2020. Residual U-Net을 이용한 토지피복지도 자동 제작 연구. 대한토목학회논문집 40권, 5호: 535-546.
Yoo, Su Hong, Lee, Ji Sang, Bae, Jun Su and Sohn, Hong Gyo. 2020. Automatic generation of land cover map using residual U-Net. *Journal of the Korean Society of Civil Engineers* 40, no.5: 535-546.
9. 이슬기, 박성재, 백경민, 김한별, 이창욱. 2019. 무인항공기(UAV) 영상을 이용한 소나무재선충병 의심목 탐지. 대한원격탐사학회지 35권, 3호: 359-373.
Seulki Lee, Sung-jae Park, Gyeongmin Baek, Hanbyeol Kim and Chang-Wook Lee. 2019. Detection of damaged pine tree by the pine wilt disease using UAV image. *Korean Journal of Remote Sensing* 35, no.3: 359-373.
10. 장순신. 2018. Sentinel-2 위성영상을 이용한 수종 분류. 석사학위논문, 서울시립대학교 도시과학대학원.
Jang Sun Sin. 2018. *Classification of Tree Species Using Sentinel-2 Satellite Image*. M.D. diss., Department of Geoinformatics The Graduate School of Urban Sciences The University of Seoul.
11. 조원호, 임용호, 박기호. 2019. 합성곱 신경망을 이용한 딥러닝 기반의 토지피복 분류: 한국 토지피복을 대상으로. 대한지리학회지 54권, 1호: 1-16.
Wonho Jo, Yongho Lim and Key-Ho Park. 2019. Deep learning based land cover classification using convolutional neural network: A case study of Korea. *Journal of the Korean Geographical Society* 54, no.1: 1-16.
12. 조기환, 정종철. 2018. 토지피복 공간정보를 활용한 자동 훈련지역 선택 기법. 지적과 국토정보 48권, 2호: 171-183.
Cho, Ki-Hwan and Jeong, Jong-Chul. 2018. Automatic

- selection method of ROI(region of interest) using land cover spatial data. *Journal of Cadastre & Land InformatiX* 48, no.2: 171-183.
13. 환경공간정보서비스. <https://egis.me.go.kr/intro/land.do> (2021년 7월 23일 검색).
Environmental Geographic Information Service. <https://egis.me.go.kr/intro/land.do> (accessed July 23, 2021).
14. Abdi, Adbulhakim. M. 2020. Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data. *GIScience & Remote Sensing* 57, no.1: 1-20.
15. Acharya, T. D., Yang I. T. and Lee D. H. 2016. Land cover classification using a KOMPSAT-3A multi-spectral satellite image. *Applied Sciences* 6, no.11: 371.
16. Cortes, C. and V. Vapnik. 1995. Support-vector networks, *Machine Learning* 20, no.3: 273-297.
17. Du, Y., Zhang, Y., Ling, F., Wang, Q., Li, W. and Li, X. 2016. 'Water bodies' mapping from Sentinel-2 imagery with modified normalized difference water index at 10-m spatial resolution produced by sharpening the SWIR band. *Remote Sensing* 8, no.4: 354.
18. He, H. and Garcia, E. A. 2009. Learning from imbalanced data. *IEEE Transactions on Knowledge & Data Engineering* 21, no.9: 1263-1284.
19. Kuc, G. and Chormański, J. 2019. Sentinel-2 imagery for mapping and monitoring imperviousness in urban areas. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 42: 43-47.
20. Maxwell, A. E., Warner, T. A. and Fang, F. 2018. Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing* 39, no.9: 2784-2817.
21. Olofsson, P., Foody, G. M., Herold, M., Stehman, S. V., Woodcock, C. E. and Wulder, M. A. 2014. Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment* 48: 42-57.
22. Rouse, J. W., Haas, R. H., Schel, I. J. A. and Deering, D.W. 1974. Monitoring vegetation systems in the great plains with ERTS. *NASA special publication* 351, vol.1: 309-317.
23. Xu, Hanqiu. 2006. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing* 27, no.14: 3025-3033.
24. Zha, Y., Gao, J. and Ni, S. 2003. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing* 24, no.3: 583-594.

-
- 논문 접수일: 2024. 04. 17.
 - 심사 시작일: 2024. 05. 02.
 - 심사 완료일: 2024. 05. 16.

요약

주제어: 토지피복변화, Sentinel-2, 서포트벡터머신, 변수중요도

본 논문은 머신러닝을 이용하여 2017년 2월부터 2018년 1월까지 Sentinel-2 영상의 시계열 토지피복변화를 비교하였다. 머신러닝 포인트 샘플링을 위해 EGIS의 디지털 토지피복지도를 참조하여 각 클래스당 동일한 지역 250개의 포인트 전체 픽셀 중 약 3%를 수집했다. 토지피복변화를 비교하기 위해 SVM(Support Vector Machine, 서포트 벡터 머신) 모델을 사용했다. 시계열 분석의 연구 결과로는 습지와 나지 면적은 증가하고 농업과 잔디 면적은 감소했으며 시가지와 산림, 수역 면적은 두 해 동안 크게 변하지 않았다. 월별 f1- 점수는 0.61~0.67 사이를 유지했으며, 4월의 f1- 점수가 가장 높았다. 오차행렬을 이용하여 정확도 검증을 실

시한 경우 수역이 가장 높은 정확도를 보였다. 주로 식물 활동과 관련된 클래스들이 종종 잘못 분류되었으며, 계절적 영향으로 식물 활동을 유발하는 클래스들과 건축물이 잘못 분류되었다는 것을 발견했다. 각 클래스의 특성은 변수의 중요도를 통해 확인되었다. 평균적으로 R, G, B, NDVI는 계절에 관계없이 높은 중요도를 보였지만 NIR, SWIR 및 Red Edge 대역은 계절에 따른 영향을 받았다. 향후 연구에서는 표본 수를 지역에 따라 상대적으로 고려하고, 훈련 영역 및 지수의 선택을 고려하여 정확도를 향상시킬 수 있을 것으로 판단된다.