

SAR 위성 영상을 이용한 수계탐지의 최적 머신러닝 밴드 조합 연구*

전현균¹ · 김덕진^{2*} · 김준우³ · 수레시 크리쉬난⁴ · 김재언⁵ · 김택인⁵ · 정승환⁵

Selection of Optimal Band Combination for Machine Learning-based Water Body Extraction using SAR Satellite Images*

Hyungyun Jeon¹ · Duk-jin Kim^{2*} · Junwoo Kim³ · Suresh Krishnan
Palanisamy Vadivel⁴ · JaeEon Kim⁵ · Taecin Kim⁵ · SeungHwan Jeong⁵

요 약

인공위성 영상을 기반으로 한 기계판독(machine interpretation) 원격탐사 수계 탐지는 효율적인 수자원 관리, 가뭄 탐지, 홍수 모니터링 등에 큰 도움이 된다. 따라서 본 연구에서는 머신러닝을 기반으로 한 SAR 위성 영상 기반 수계 탐지를 시행하였다. 그러나 SAR 위성 영상만을 사용하였을 경우 음영 효과 또는 도로 등의 수계와 비슷한 산란특성을 가지는 물체로 인하여 비수계가 수계로 오탐지 될 수 있다. 이러한 오탐지를 줄이기 위하여 목포 지역을 촬영한 Cosmo-SkyMed SAR 위성 영상에 모폴로지(Morphology)의 open 연산을 거친 밴드와 DEM(수치표고모델) 밴드, Curvature(곡률) 밴드를 조합하여 중첩한 8가지 경우에 대하여 의미 분할 기법 머신러닝 모델을 학습시켰다. 8가지 머신러닝 모델에 대한 최종 테스트 결과인 Global Accuracy를 구하였으며, 목

2020년 07월 29일 접수 Received on July 29, 2020 / 2020년 08월 22일 수정 Revised on August 22, 2020 / 2020년 08월 24일 심사완료 Accepted on August 24, 2020

* 본 논문은 해양수산과학기술진흥원 KIMST의 다중위성 기반 해양 현안대응 실용화 기술 개발 사업으로부터 지원을 받았으며(no: 20180456/SAR위성 기반 해양 부유물 탐지 기술 개발), 또한 행정안전부 MOIS의 위성 무인기 등 다채널 영상정보를 활용한 연속적 재난상황 인지 및 위험 모니터링 기술 개발 사업으로부터 지원을 받았습니다(2019-MOIS32-015). 본 연구에서 활용한 Cosmo-SkyMed 위성 자료는 CSK Products, ASI(Italian Space Agency)를 사용하였으며, 이는 ASI의 허가를 받아 획득되어 사용되었습니다. 또한 본 연구에서 사용된 토지피복지도는 환경부에서 제작한 것입니다.

- 1 서울대학교 지구환경과학부 석·박사과정생 School of Earth and Environmental Sciences, Seoul National University, Combined MS/PhD Student
- 2 서울대학교 지구환경과학부 정교수 School of Earth and Environmental Sciences, Seoul National University, Professor
- 3 서울대학교 지구환경과학부 박사후연구원 School of Earth and Environmental Sciences, Seoul National University, Postdoctoral Researcher
- 4 서울대학교 지구환경과학부 박사수료생 School of Earth and Environmental Sciences, Seoul National University, PhD Candidate
- 5 서울대학교 지구환경과학부 학부생 School of Earth and Environmental Sciences, Seoul National University, Undergraduate Student

* Corresponding Author E-mail : djkim@snu.ac.kr

포 지역의 토지피복지도와의 일치율 역시 비교하였다. 그 결과 SAR 위성 영상과 모폴로지 open 필터를 적용한 밴드, DEM 밴드, Curvature 밴드를 모두 사용한 경우가 Global Accuracy뿐만 아니라 토지피복지도와의 일치율 역시 가장 높음을 확인할 수 있었다. 이때 Global Accuracy는 95.07%였으며, 토지피복지도와의 일치율은 89.93%로 나타났다.

주요어: 수계 탐지, SAR, Cosmo-SkyMed, 모폴로지, 지형정보, 머신러닝, 토지피복지도

ABSTRACT

Water body detection using remote sensing based on machine interpretation of satellite image is efficient for managing water resource, drought and flood monitoring. In this study, water body detection with SAR satellite image based on machine learning was performed. However, non water body area can be misclassified to water body because of shadow effect or objects that have similar scattering characteristic comparing to water body, such as roads. To decrease misclassifying, 8 combination of morphology open filtered band, DEM band, curvature band and Cosmo-SkyMed SAR satellite image band about Mokpo region were trained to semantic segmentation machine learning models, respectively. For 8 case of machine learning models, global accuracy that is final test result was computed. Furthermore, concordance rate between landcover data of Mokpo region was calculated. In conclusion, combination of SAR satellite image, morphology open filtered band, DEM band and curvature band showed best result in global accuracy and concordance rate with landcover data. In that case, global accuracy was 95.07% and concordance rate with landcover data was 89.93%.

KEYWORDS : *Water body detection, SAR, Cosmo-SkyMed, Morphology, Terrain information, Machine Learning, Landcover data*

서 론

수계 영역을 추출하고 그 면적을 계산하는 것은 홍수 모니터링, 수자원 관리, 가뭄의 심각도를 파악하는 데 중요하다(Shen and Li, 2010; Lee et al., 2017). 인공위성 영상은 넓은 지역을 일정한 시간 간격으로 촬영하므로 이러한 수계 탐지를 위해 주로 사용되었다.

광학 위성은 다분광 정보를 획득할 수 있어 NDWI와 같은 지수 기반의 분석이 가능하지만, 기상 상황이 좋지 않을 때나 밤에는 영상 획득이 불가능하다(Huang et al., 2018). 반면에 SAR 위성은 마이크로파를 사용하므로 구름을 통과하여 집중 호우 시에도 영상 획득이 가능하

고 한밤중에 발생하는 홍수도 촬영할 수 있다. 또한, SAR 위성에서 방사된 마이크로파는 수면에서는 거의 거울 반사(specular reflection)가 발생하기 때문에 어둡게 보여 SAR 위성 영상에서 수계와 비수계를 구분하는데 수월하다(Kim et al., 2019).

지금까지의 SAR 영상 기반 수계 탐지는 주로 후방산란계수가 낮은 지역을 구분하는 threshold 기법 기반의 연구가 이루어졌다(Kim et al., 2019). Threshold 기법 기반의 연구는 수계와 비슷한 방사 응답 특성을 가지는 산란체, Side-Looking을 하는 SAR 영상의 특성으로 인해 발생하는 음영 지역 및 speckle noise를 효과적으로 걸러내는 최적의 threshold 값을 찾기 어렵다는 문제가 있다(Ouchi, 2004;

Sghaier *et al.*, 2017).

이러한 한계로 인해, 본 연구에서는 최근 주목받고 있는 Convolutional Neural Network (CNN) 기반의 머신러닝 기법을 활용하여 수계 탐지 연구를 진행하였다. CNN 기반의 머신러닝을 이용할 경우 이미지 픽셀값의 공간적인 분포가 학습되기 때문에 수계와 산 뒤쪽 사면의 어두운 부분 그리고 도로 등의 수계와 비슷한 산관특성을 나타내는 물체를 구분할 수 있는 잠재력이 있다. 선행 연구에서는 threshold 기법 기반으로 지형정보와 SAR 위성 영상을 조합하여 오탐지를 줄인 좋은 결과를 얻었으나, 아직 SAR 위성 영상과 지형정보를 조합하여 머신러닝을 하였을 때 오탐지를 최소화하는 방안에 관한 연구는 완성되지 않았다(Hong *et al.*, 2015).

따라서 본 연구에서는 Cosmo-SkyMed X-밴드 SAR영상과 모폴로지 필터(Morphological filter)를 적용한 영상, 그리고 수치표고모델(Digital Elevation Model; DEM)와 지형 곡률(Curvature) 정보를 추가하여 머신러닝을 이용한 수계 탐지에서 오탐지를 최소화할 수 있는 최적의 밴드 조합에 관해 연구하였다.

연구 자료, 연구 지역 및 전처리

1. 연구 자료

본 연구에서는 이탈리아의 Agenzia Spaziale Italiana (ASI)에서 운영하고 있으며 Stripmap HIMAGE 모드로 촬영되고 공간 해상도가 3m 인 Cosmo-SkyMed SAR 위성 영상 자료 2장을 사용하였다(표 1). 2018년 8월 17일에 촬영된 Cosmo-SkyMed 영상을 학습자료(training data)를 제작하는 데 사용하였고, 2014년 5월

2일에 촬영된 영상을 학습모델의 테스트를 위해 사용하였다. 머신러닝을 통한 수계 탐지의 정확도 평가를 위해 2014년 4월 28일에 제작된 토지피복지도를 사용하였다. 지형정보를 위해 수치표고모델인 SRTM-DEM과 이로부터 추출된 지형 곡률(Curvature)을 사용하였다. 2000년에 제작된 SRTM-DEM은 비록 제작 시기가 오래되었지만, 획득이 쉬우며 더 나중에 제작된 DEM인 ALOS World 3D 30m과 비교하였을 때 서로 높은 상관관계가 있으며 유사한 통계를 보여주므로 본 연구에 사용하였다(Yang *et al.*, 2018).

2. 연구 지역

연구 지역은 전라남도 목포시 일대의 영산강 유역으로서 그 영역은 그림 1과 같다. 목포시는 전라남도 서남부 무안반도 남단에 위치하며, 목포시를 흐르는 영산강은 전남 담양군에서 시작하여 황룡강, 지식천, 고막원천, 함평천의 지류 등의 많은 지류가 발달하여 있다. 영산강 유역의 평야 대부분은 퇴적, 침식 작용이 심하고 계절에 따른 유량의 차이가 매우 심하여 홍수의 위험성이 높다(Ministry of Land, Infrastructure and Transport, 2013). 연구 지역인 목포시 일대는 이러한 영산강 하류에 위치하고 있어 계절적 수위 변화 및 홍수로 인한 저지대의 침수 및 수변 지역의 범람을 모니터링할 필요가 있는 지역이다.

3. 전처리

본 연구에서는 Cosmo-SkyMed SAR 위성 영상의 VV 편파에 대하여 방사보정 후 지오큐딩을 진행하였다(Pulvirenti *et al.*, 2011). 보

TABLE 1. Data used in this study

	Date	Resolution	Polarization	Data type
Cosmo-SkyMed	2018.08.17	3m	VV	Training
	2014.05.02	3m	VV	Test
Land-cover	2014.04.28	1:25000		Validation
DEM	2000.02.11.~2000.02.22	90m		Ancillary Input
Curvature	2000.02.11.~2000.02.22	90m		Ancillary Input




FIGURE 1. Area of interest in this study (Mokpo). Black and white images are SAR image and overlaid blue area is water body defined by landcover data

정이 끝난 SAR 위성 영상에 대하여 모폴로지 필터를 적용하였다. 모폴로지 필터는 영상에서 객체의 형태 및 구조에 대해 분석하고 처리하는 기법으로, 객체의 모양을 단순화시키거나 잡음을 제거하는 데에 사용된다. 본 연구에서는 입력 영상에 존재하는 작은 크기의 밝은 객체를 제거하는 효과가 있는 open 연산을 수행하였다 (Hwang, 2019). 그 이유는 open 연산을 수행하면 SAR 위성 영상에서의 speckle 노이즈가 제거되어 SAR 위성 영상의 공간적인 정보가 극대화될 것으로 판단했기 때문이다 (Moslem *et al.*, 2016). Open 연산에 사용된 구조 요소로는 5×5 픽셀 크기의 정사각형 행렬을 사용하였다. 구조 요소가 지나치게 작으면 노이즈가

제거되지 않으며 구조 요소가 지나치게 크면 탐색 대상인 수계까지 삭제되므로 5×5 크기의 구조 요소를 사용하였다.

SAR의 후방산란계수와 SAR 영상으로부터 모폴로지 필터 적용 후 생성된 open 영상 외에 수계 탐지에 도움이 될 수 있는 지형정보도 추가하였다. 추가된 지형정보는 수치표고모델 (DEM)과 곡률(Curvature)이다. 일반적으로 계곡과 하천은 주변보다 낮은 곳에 존재하기에 높이 정보가 바로 수계의 존재 확률을 결정지을 수 있으며, 곡률의 경우 위로 볼록한 지형보다는 아래로 오목한 지형에서 물이 고여 있을 확률이 높기 때문이다. 수치표고모델로부터 곡률의 계산을 위해서 ArcGIS 10.5 프로그램을 사




FIGURE 2. Example of four bands used in this study

용하였다.

대부분의 머신러닝 알고리즘은 다양한 입력 자료가 유사한 범위를 가질 때 좋은 성능을 보인다는 연구결과가 있기에(Raschka and Mirjalili, 2019), 후방산란계수와 모폴로지 그리고 지형정보가 모두 0~1 사이에 존재하도록 정규화를 수행하였다. 후방산란계수인 σ° 의 경우 대부분의 값이 0~1 사이에 존재하기 때문에(linear scale) 정규화를 위해 1보다 큰 값을 1로 재설정하였다(실제로 후방산란계수가 1보다 큰 물체는 대부분 인공구조물이기에 수계 탐지에서는 고려하지 않아도 되는 대상이다). DEM과 curvature와 같은 지형정보 또한 [0, 1]로 맞추기 위하여 식 1과 같은 정규화를 수행하였다(Dou *et al.*, 2015). 보정된 SAR 위성 영상, 모폴로지 open 연산을 거친 SAR 위성 영상, DEM, Curvature 밴드의 모습은 그림 2와 같다.

$$\frac{(DN - Min)}{(Max - Min)} \quad (1)$$

DN : Pixel value of input layer

Max : Maximum value of input layer

Min : Minimum value of input layer

연구 방법

1. 학습자료 생성

본 연구에서는 2018년 8월 17일에 촬영되고 전처리된 Cosmo-SkyMed SAR 위성 영상을 1,000×1,000 픽셀로(약 9제곱킬로미터의 넓이) 잘라준 후 생성된 이미지 패치들에 대해 구글 어스 상의 광학 영상과 비교해가며 visual interpretation으로 총 105개의 라벨링 된 학습 자료를 생성하였다. 이때 강의 영역뿐만이 아닌 강을 지나는 다리와 저수지 등의 세세한 영역까

지 구분하여 학습자료의 정확도 및 정밀도를 높였다.

2. 머신러닝 모델 생성 및 모델 학습

본 연구에서의 머신러닝 기법은 이미지 의미 분할 알고리즘 중 SegNet 알고리즘을 변형한 Simple SegNet을 사용하였다. Simple SegNet을 구현하는 데에는 Matlab 2020a 프로그램을 사용하였다. SegNet은 2017년에 소개된 이미지 의미 분할 알고리즘으로, 픽셀 단위에서 이미지를 분할 해 줄 수 있는 특징이 있다.

SegNet은 최초의 의미 분할 머신러닝 기법인 FCN에 비해 진보된 성능을 보이고, 다른 의미 분할 머신러닝 기법인 DeepLab-LargeFOV, Deconvnet 등과 비교하였을 때도 좋은 성능을 보여 기본 알고리즘으로 SegNet을 선택하였다 (Badrinarayanan *et al.*, 2017). Simple SegNet은 인코더-디코더 깊이가 5였던 원본 SegNet을 인코더-디코더 깊이를 3으로 한 모델이다. SegNet은 인코더에서 이미지의 특징을 추출하고 디코더에서 이미지의 해상도를 복원하는데, 깊이가 깊을수록 이미지의 해상도를 복원

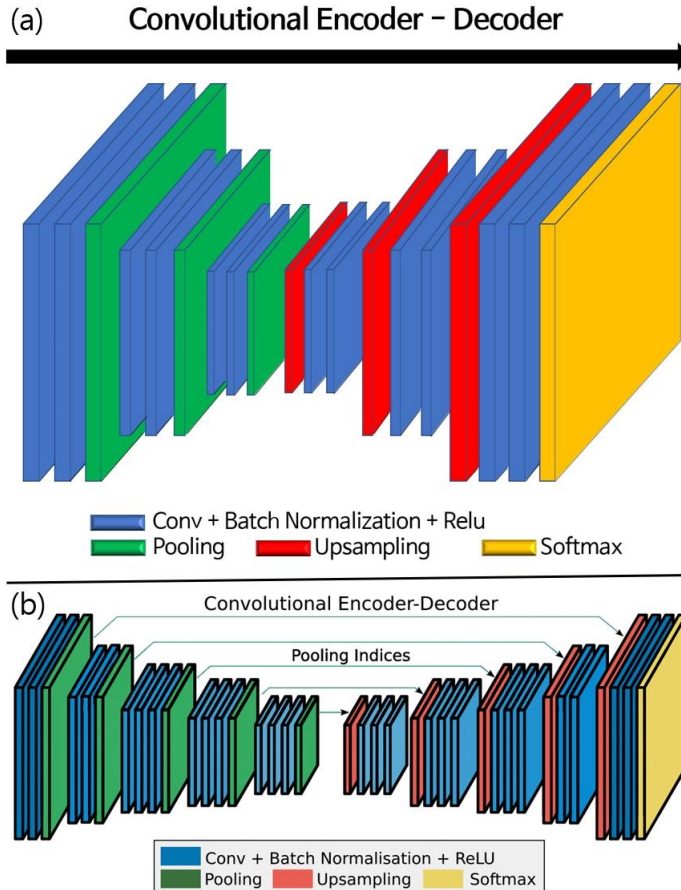


FIGURE 3. (a) The structure of Simple SegNet. (b) The structure of original SegNet. There are ten aggregate of machine learning layers in original SegNet but Simple SegNet has six aggregate of machine learning layers

TABLE 2. Combination of input bands for each case

Case Number	Combination of input bands
Case 1	SAR Image
Case 2	SAR Image, Opened SAR Image
Case 3	SAR Image, DEM
Case 4	SAR Image, Curvature
Case 5	SAR Image, Opened SAR Image, DEM
Case 6	SAR Image, Opened SAR Image, Curvature
Case 7	SAR Image, DEM, Curvature
Case 8	SAR Image, Opened SAR Image, DEM, Curvature

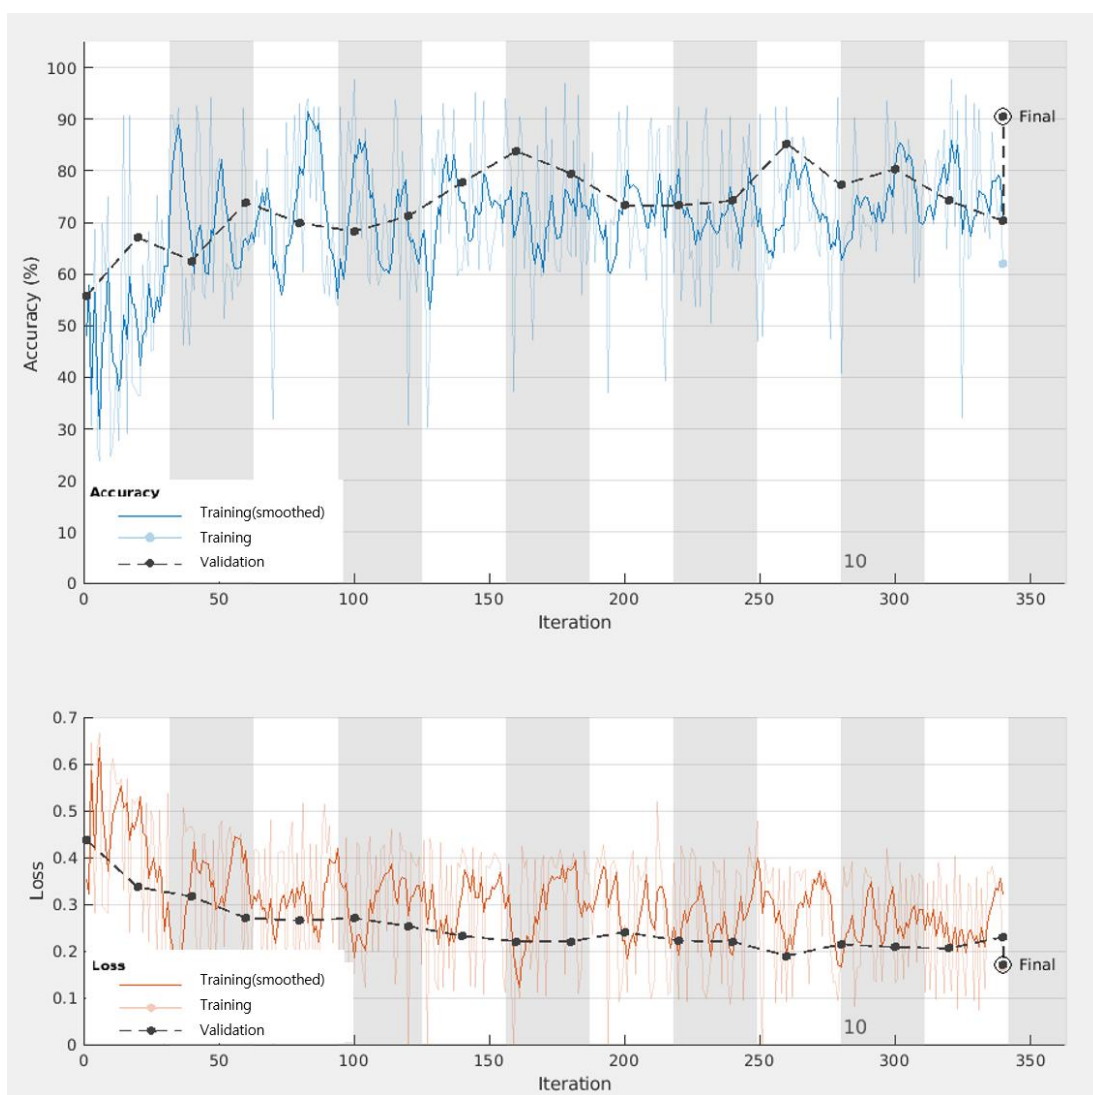


FIGURE 4. Training Progress of Case 8. In this case, training was stopped at epoch 11

하는 과정에서 이미지가 지나치게 추상화되는 오분류가 생길 가능성이 있으므로 원본 SegNet에 비해 단순한 모델을 만들어 분석하였다. 또한, Simple SegNet의 구조는 그림 3과 같다.

Simple SegNet 구조에 input으로 전처리되고 중첩된 8가지 경우의 Cosmo-SkyMed SAR 위성 영상 기반 Geotiff 파일을 넣어준 후, 각각의 Case에 대해 정확도(Global Accuracy)를 분석해주었다. 각각의 Case의 밴드 조합은 표 2와 같으며, Global Accuracy의 정의는 식 2와 같다(Tonmoy *et al.*, 2018). 이때 105개의 이미지 패치는 6:2:2의 비율로 무작위하게 학습, 검증, 최종 정확도 테스트를 위한 데이터 세트로 분할되었다.

$$Global\ Accuracy = \frac{\sum_i n_{ii}}{\sum_i t_i} \quad (2)$$

n_{ii} : the number of pixels of class i predicted to belong to class I

t_i : the total number of pixels of class I

모델 학습은 최대 40 Epoch만큼 반복되게 설정하였으며, validation accuracy가 4 Epoch 이상 동안 증가하지 않으면 자동으로 학습을 중단하도록 하였다. 실제 모델 학습 과정 및 수립되는 과정의 그림은 그림 4와 같다(Case8에 대해 진행하였다).

3. 토지피복도 이용 머신러닝 모델 분석 결과 정확도 비교

본 연구에서는 환경부에서 제작한 목포 지역의 2014년 4월 28일에 제작된 중분류 토지피복지도(1:25000 축척)를 사용하여 2차 검증을 하였다. 이때 원래의 토지피복지도가 수계/비수계 뿐만이 아닌 다양한 종류로 지표물을 분류하기 때문에, 토지피복지도의 분류를 수계/비수계 분류로 단순화시켜주었다. 그 후 조수간만의 차이가 거의 없는 내륙 지방에 대해 토지피복지도를 shape 파일에서 raster(geotiff 형식) 파일로 변환한 후, 머신러닝 모델의 분석 결과 raster(geotiff 형식) 파일과 일치율을 비교하였다.

결 과

본 연구에서는 제작한 학습자료에 대한 8가지의 case에 대하여 각각 의미 분할 기법 머신러닝 모델을 학습시켰다. 8개 머신러닝 모델의 Global Accuracy는 표 3과 같다. 또한, 단순히 머신러닝 과정에서 추출되는 정확도뿐만이 아니라, 실제 목포 지역에 대한 토지피복지도와의 비교 검증 역시 실시하였다. 의미 분할 기법으로 분석된 8가지 경우의 영상은 그림 5와 같으며, 가장 좋은 분류결과인 case 8과 원본 SAR 영상, 토지피복지도를 나열한 그림은 그림 6과 같다. 토지피복지도와 분석된 결과의 일치율은 표 4와 같다.

분석 결과 SAR 위성 영상과 모폴로지 open 연산을 거친 SAR 위성 영상, DEM, Curvature

TABLE 3. Global accuracy of eight cases.

Case Number	Combination of input bands	Global Accuracy (%)
Case 1	SAR Image	89.07
Case 2	SAR Image, Opened SAR Image	91.45
Case 3	SAR Image, DEM	93.87
Case 4	SAR Image, Curvature	73.57
Case 5	SAR Image, Opened SAR Image, DEM	87.48
Case 6	SAR Image, Opened SAR Image, Curvature	93.95
Case 7	SAR Image, DEM, Curvature	94.15
Case 8	SAR Image, Opened SAR Image, DEM, Curvature	95.07

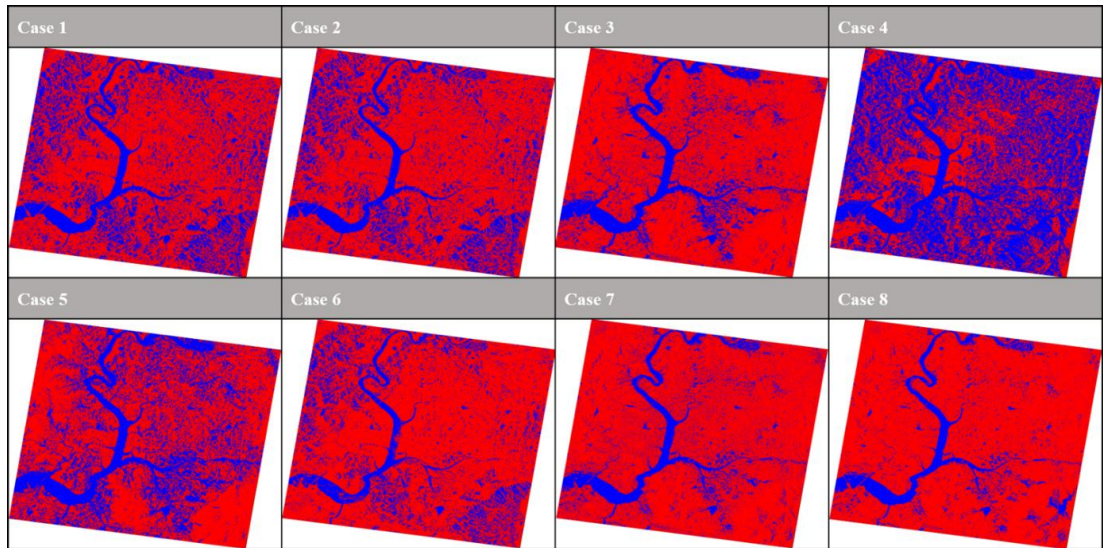


FIGURE 5. Machine Learning Results of 8 cases. Red area is land and blue area is water. Case 8 shows the best result




FIGURE 6. Original SAR Image, Landcover Image and Case 8. Red area is land and blue area is water

TABLE 4. Concordance rate between Machine Learning Result and landcover Data.

Case Number	Combination of input bands	Concordance rate between Machine Learning Result and landcover Data (%)
Case 1	SAR Image	72.99
Case 2	SAR Image, Opened SAR Image	75.96
Case 3	SAR Image, DEM	84.58
Case 4	SAR Image, Curvature	49.63
Case 5	SAR Image, Opened SAR Image, DEM	72.22
Case 6	SAR Image, Opened SAR Image, Curvature	82.24
Case 7	SAR Image, DEM, Curvature	87.15
Case 8	SAR Image, Opened SAR Image, DEM, Curvature	89.93

를 모두 중첩해 머신러닝 알고리즘을 적용하는 것이 머신러닝 과정에서 계산되는 Global Accuracy와 Ground Truth Data로 사용한 토지피복지도와의 일치율이 모두 가장 높음을 알 수 있었다.

고찰 및 결론

수계 탐지는 하천 환경 관리, 수자원 확보, 기물 예방 등에 중요하다. 수계 탐지의 대상 영역이 넓으므로, 수계 탐지는 인공위성을 이용한 원격탐사 방식으로 수행하는 것이 필수적이다. 현재까지 국내에서의 인공위성 기반 수계 탐지는 환경부에서 제작하는 토지피복지도가 가장 공신력이 있다. 그러나 수계의 변화를 시계열적으로 분석하고 탐지하는 것이 필수적인 것에 비하여, 토지피복지도는 제작 주기가 수 년 단위가기 때문에 수계를 시계열적으로 탐지하여 변화를 알아내고 대응하는 데에는 한계가 있다. 그런데 넓은 범위에 관한 원격탐사 자료를 visual interpretation으로 짧은 주기로 분석하는 데에는 비용이 많이 들기 때문에, 본 연구에서는 최근 주목받는 머신러닝 기법 중 의미 분할 기법의 하나인 SegNet을 기반으로 수계를 탐지하였다. 그러나 SAR 위성 영상만 사용하면 비수계가 수계로 오탐지 될 수 있어, 추가적인 밴드를 중첩하는 것이 필수적이다. 그러나 아직 어떠한 밴드를 중첩해야 오탐지를 최대한 줄일 수 있는지는 확실히 알려지지 않았다.

본 연구에서는 비수계의 수계 오탐지를 줄이기 위하여 단순히 SAR 위성 영상뿐만이 아닌, 모폴로지 open 연산을 거친 SAR 위성 영상, 그리고 수치표고모델(DEM)과 곡률(Curvature)을 중첩해 여러 가지 조합에서 실험을 진행하였다. 그 결과 추가적인 밴드를 모두 사용한 case 8이 머신러닝 과정에서의 자체 정확도 및 토지피복지도와의 일치율이 가장 높으며, 비수계가 수계로 오탐지되는 현상이 그림 5와 그림 6에서 보듯 가장 적음을 알 수 있었다.

우선 모폴로지 open 연산을 거친 밴드의 효과에 관해서는, open 연산의 특징상 작은 객체

가 삭제되어 SAR 위성 영상에 존재하던 노이즈가 사라진 결과 SAR 위성 영상의 공간적인 특성이 극대화된 밴드가 되었기 때문에 다른 추가 밴드 없이 SAR 위성 영상과 조합했을 때에도 Global Accuracy 및 토지피복지도와의 일치율이 모두 높아졌다고 판단된다(표 3과 표 4에서 case1, case2를 비교한 결과).

DEM 밴드의 효과에 관해서는, 물이 높은 곳에서 낮은 곳으로 흐르는 성질이 있으므로 DEM의 값이 낮을수록 특정 영역이 수계일 가능성이 크다고 판단하고 추가 밴드로 투입하였다. 표 3과 표 4에서 case1, case3을 비교한 결과 Global Accuracy와 토지피복지도와의 일치율이 모두 높아졌기 때문에 DEM이 물의 존재에 영향을 미친다는 가설은 맞다고 볼 수 있다.

Curvature 밴드의 효과에 관해서는, 표 3과 표 4에서 case1에 비해 case4의 값이 모두 낮기 때문에 Curvature 만으로는 수계 탐지에 긍정적인 영향을 주지 못한다고 볼 수 있다. 그러나 Curvature가 다른 추가 밴드에 보조적으로 투입된 case6, case7, case8의 Global Accuracy 및 토지피복지도와의 일치율이 모두 case1에 비해 높으므로 Curvature은 보조 밴드로서는 충분한 기능을 한다고 판단된다.

본 연구의 기여로는 SAR 위성영상과 추가적인 지형정보를 사용한 선행 연구에 비해 최적의 threshold 값을 찾는 복잡한 과정 없이도 거의 비슷한 수준의 정확도를 달성했다는 점이 있다. 선행 연구에서의 최종 정확도는 96.42%였음에 비해 본 연구의 최종 정확도는 95.07%로 거의 차이가 없으나, 본 연구에서 만든 머신러닝 모델은 threshold 모델과는 다르게 범용적으로 사용할 수 있어서 훨씬 잠재력이 높다고 볼 수 있다(Hong et al., 2015).

본 연구의 한계로는 105개라는 머신러닝 모델 학습자료의 수가 충분하지 않을 수 있다는 점, 학습자료 제작을 visual interpretation 기반으로 하였기 때문에 주관적인 판단이 들어갈 수 있다는 점, SegNet이 아닌 다른 머신러닝 알고리즘들에 대해 비교를 하지 않은 점, DEM 자료를 최신 DEM이 아닌 SRTM DEM을 사용

하였기에 오차가 생길 수 있다는 점, 토지피복 지도가 2014년 4월 28일에 제작되었으나 제작에 사용된 영상들의 정확한 취득 시기를 모른다는 점 등이 있다.

앞으로 토지피복지도를 사용하여 학습자료 생성을 자동화하는 등 더욱 객관적인 학습자료를 다량으로 제작하고, 최신의 DEM을 사용하며, 다양한 머신러닝 알고리즘을 사용하여 성능을 비교하고, 정확한 Ground Truth Data와 비교를 할 방안을 마련하여 더 넓은 지역을 대상으로 하는 추가 연구가 필요하다. **KAGIS**

REFERENCES

- Badrinarayanan, V., A. Kendall and R. Cipolla. 2017. Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE Transactions on pattern analysis and machine intelligence* 39(12):2481-2495.
- Dou, J., H. Yamagishi, H. R. Pourghasemi, A. P. Yunus, X. Song, Y. Xu and Z. Zhu. 2015. An integrated artificial neural network model for the landslide susceptibility assessment of Osado Island. *Japan Natural Hazards* 78(3): 1749-1776.
- Hong, S., H. Jang, N. Kim and H. Sohn. 2015. Water area extraction using RADARSAT SAR imagery combined with landsat imagery and terrain information. *Sensors* 15(3):6652-6667.
- Huang, W., B. DeVries, C. Huang, M. W. Lang, J. W. Jones, I. F. Creed and M. L. Carroll. 2018. Automated extraction of surface water extent from Sentinel-1 data. *Remote Sensing* 10(5):797.
- Hwang, S. K. 2019. Computer vision and machine learning with Opencv4. Gilbut, Seoul, pp.369-378. (황선규. 2019. OpenCV 4로 배우는 컴퓨터 비전과 머신러닝, 369-378 쪽, 길벗, 서울).
- Kim, Y., M. Lee and S. Lee. 2019. Detection of change in water system due to collapse of Laos Xe pian-Xe namnoy dam using KOMPSAT-5 satellites, *Korean Journal of Remote Sensing* 35(6_4):1417-1424 (김윤지, 이명진, 이선민. 2019. KOMPSAT-5 위성 영상을 활용한 라오스 세피안-세남노이 댐 붕괴에 따른 수계변화 탐지. *대한원격탐사학회지* 35(6_4):1417-1424).
- Lee, S. B., Y. Kim, J. Kim and Y. Park. 2017. Detection of alteration in river area using Landsat satellite imagery. *Journal of the Korean Society of Hazard Mitigation* 17(3):391-398 (이수봉, 김용민, 김진영, 박영진. 2017. Landsat-8 위성 영상을 이용한 수계면적 변화 탐지. *한국방재학회지* 17(3):391-398).
- Li, S and C. Li. 2010. Water body extraction from Landsat ETM+ imagery using adaboost algorithm. 18th International Conference on Geoinformatics, Beijing, China, June. 18-20, pp.1-4.
- Ministry of Land, Infrastructure and Transport. 2013. List of rivers in Korea, pp.1-107. (국토교통부. 2013. 한국하천일람, 1-107 쪽).
- Ouchi, K. 2004. Principles of synthetic aperture radar for remote sensing. Tokyo Denki University Press, Tokyo, pp.133.
- Pulvirenti, L., M. Chinib, N. Pierdiccaa, L. Guerrieroc, and P. Ferrazzolic. 2011. Flood monitoring using multi-temporal

- COSMO-SkyMed data: Image segmentation and signature interpretation. *Remote Sensing of Environment* 115(4):990-1002.
- Raschka, S. and V. Mirjalili. 2019. *Python Machine Learning: Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow 2*. Packt Publishing Ltd, Birmingham, pp.153.
- Sghaier, M. O., S. Foucher and R. Lepage. 2016. River extraction from high-resolution SAR images combining a structural feature set and mathematical morphology. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 10(3), 1025-1038.
- Tonmoy, G., L. Li and J. Chakareski. 2018. Effective deep learning for semantic segmentation based bleeding zone detection in capsule endoscopy images. 25th IEEE International Conference on Image Processing(ICIP), Athens, Greece, Oct. 7-10, pp.3034-3038.
- Yang, I., D. Lee, T. D. Acharya and D. Han. 2018. AW3D30 and SRTM30 Digital Elevation Models - comparison around coastal islands in Gyeongsangnam-do, South Korea. *Journal of the Korean Association of Geographic Information Studies* 21(2):34-43 (양인태, 이동하, 아차르야트리테브. 한동석, 2018. AW3D30 DEM과 SRTM30 DEM의 정확도 비교 -경상남도 연안도서를 중심으로-. *한국지리정보학회지* 21(2):34-43). **KAGIS**