

# 인공지능 학습용 데이터 기반의 산림 수종 분석 모델

정한균\*, 김종인\*, 고선영\*, 채승기\*\*, 신용태\*\*\*

\*송실대학교 IT정책경영학과 박사과정

\*\* (주)올포랜드

\*\*\*송실대학교 컴퓨터공학부 교수

hankunch@naver.com, jikim0110@naver.com, fallhasgone@gmail.com,

sgchai@all4land.com, shin@ssu.ac.kr

## Forest Tree Species Analysis Model based on Artificial Intelligence Learning Data

Hankun Chung\*, Jong-in Kim\*, Sun Young Ko\*, Seung-Gi Chai\*\*, Youngtae Shin\*\*\*

\*Doctoral Degree, IT Policy and Management, Soongsil University

\*\*Dept. of Computer Engineering, ALLforLand

\*\*\*Professor, Dept. of Computer Science, Soongsil University

### 요 약

4차 산업혁명 시대가 도래하면서 세상이 빠른 속도로 변하고 있다. 특히 데이터·인공지능(AI, Artificial Intelligence)의 활용이 적극적으로 다양한 분야에서 적용되기 시작하고 있다. 하지만 산림 수종을 분석하는 업무를 수행하는 과정은 수작업으로 진행하다 보니 오류가 다수 발생하고 있다. 따라서 본 논문에서는 수도권 항공사진을 이용하여 소나무, 낙엽송, 침엽수, 활엽수를 대상으로 자동으로 분석하는 AI 학습용 데이터 약 60,000장을 구축하고, 수종을 구분할 수 있는 AI 모델을 개발하였다. 이를 통해 산림변화탐지 및 산림 분야 주제도 제작 시 수종 분할 이미지를 기초자료로 활용함으로써 업무효율 증대를 기대할 수 있다.

### 1. 서론

한국판 디지털 뉴딜은 디지털 전환을 가속화하고 비대면 산업을 육성해 새로운 성장 동력을 확보하기 위한 산업정책으로서, 개방된 공공 데이터를 활용하는 데이터 댐 사업이 중심이 되어 인공지능 학습용 데이터의 플랫폼을 구축해 가고 있다. 2017년부터 21종 460만 건의 인공지능 학습용 데이터를 구축하여 민간에 개방하고 있다. 그중에서 수도권, 강원·충청 지역의 환경변화 탐지 및 산림 자동 분할기술 개발을 위한 이미지 AI 학습용 데이터 4종(국토환경 분야)을 구축하였다.[1]

우리나라 산림은 국토의 63%를 차지하는 국가 발전의 터전으로 지속 가능한 보전과 이용 기술 필요하다. 하지만, 산림 수종 분류를 육안 판독에 의존하고 있어 작업자 휴면오류, 대규모 자원 투입 및 실시간 현행화가 불가능한 상황이다.







따라서, 본 논문에서는 산림의 디지털화를 통한 변화탐지, 고품질 학습용 이미지 데이터 확보를 통한 자동 분류체계 방안을 제시하고자 한다.

### 2. 산림 수종 학습용 데이터 개요

#### 2.1 산림 수종 학습용 데이터 설계

산림 수종 학습용 데이터는 국토지리정보원 항공 영상(해상도 25cm)을 활용하여, Fine annotation 22,977장, Coarse annotation 37,915장 총 60,892장의 데이터를 구축하였다.[2] 수종은 소나무, 낙엽송, 기타침엽수, 활엽수로 구분하고, ‘판독불가’와 ‘비산림’을 합하여 총 6개의 클래스로 구분하였다.

<표 1> 산림 수종 학습용 데이터 항공 이미지 클래스 분류

코드	항목명	R	G	B	색상	Gray Scale
N01	소나무	165	145	104		110
N02	낙엽송	191	150	119		120
N03	기타 침엽수	129	94	41		130
N04	활엽수	198	235	97		140
N08	판독불가	0	0	0		0
N09	비산림	204	204	204		190

메타데이터 구성 항목 중 이미지 식별자는 원시 이미지 파일명을 나타내고, 이미지 너비 및 높이 정보는 학습을 위한 데이터의 크기(기본 512x512)를

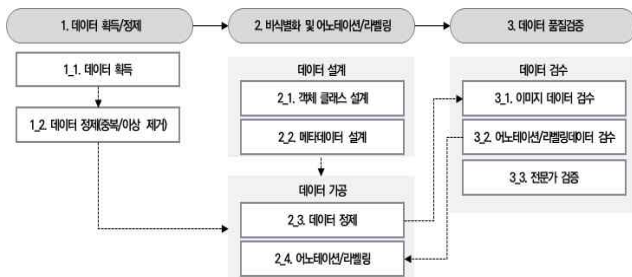
나타낸다. 이미지 좌표계 EPSG(European Petroleum Survey Group) 코드는 전 세계 좌표계 정의에 대한 고유 명칭을 뜻하며, 그 중 EPSG:5186는 GRS80 타원체의 한국 중부원점, X축으로 200,000미터, Y축으로 600,000미터 만큼 이동시킨 좌표계를 나타낸다.

<표 2> 산림 수종 학습용 데이터 메타데이터 구성

No	항목		타입	필수 여부
	영문명	한글명		
1	Image	원시 이미지 정보		
1-1	img_id	원시 이미지 식별자	String	Y
1-2	img_width	원시 이미지 너비	Number	Y
1-3	img_height	원시 이미지 높이	Number	Y
1-4	img_type	원시 이미지 종류	String	Y
1-5	img_coordinate	원시 이미지 좌표계	String	Y
1-6	coordinates	원시 이미지 좌상단 좌표	String	Y
1-7	img_resolution	원시 이미지 해상도	Number	
1-8	img_provid	원시 이미지 제공기관	String	Y
1-9	img_time	원시 이미지 촬영시기	String	Y
1-10	img_winter	참조 이미지 겨울 유무	String	Y
2	annotations	어노테이션 정보		
2-1	ann_id	어노테이션 식별자	String	Y
2-2	ann_type	어노테이션 타입	String	Y
2-3	ann_file_type	어노테이션 파일 유형	String	Y
3	provided	제공기관 정보		
3-1	provided_nm	제공기관명	String	Y

2.2 산림 수종 학습용 데이터 구축

고품질의 학습용 데이터를 구축하기 위해 3단계의 구축 절차를 적용하였다. 데이터 획득에서부터 검증단계까지 상세 작업공정에 대한 표준 가이드라인을 수립하여 진행하였다.[3]



(그림 1) 학습용 데이터 구축 절차

6종 어노테이션 클래스 분류기준으로 다음과 같다. 소나무(N01)는 산림 내의 수목 중 소나무와 곰솔을 구획하며, 촬영 경사각에 의해 기울어진 구획은 영상에 보이는 그대로 구획한다. 낙엽송(N02)은 산림 내의 수목 중 낙엽송을 구획하며, 촬영 경사각에 의해 기울어진 구획은 영상에 보이는 그대로 구획한다. 겨울 영상에서는 낙엽송 구분이 활엽수와 비슷하여 최대한 여름

영상을 이용한다. 기타 침엽수(N03)는 산림 내의 수목 중 잣나무, 편백, 삼나무 등 기타침엽수를 구획하고, 촬영 경사각에 의해 기울어진 구획은 영상에 보이는 그대로 구획한다. 활엽수(N04)는 산림 내의 수목 중 활엽수를 구획하며, 수관 축 중심이 아닌 수관 경계를 기준으로 구획하며 그림자는 포함하지 않는다. 산림 내의 혼효림, 조림지, 그림자 등 수종 판독이 불가능한 지역은 판독불가(N08) 지역이며, 비산림(N09)은 주거지, 벌채지, 경적지, 수채, 과수원 등이 해당된다.

<표 3> 산림 수종 학습용 데이터 어노테이션 분류기준

코드	항목명	어노테이션 분류
N01	소나무	
N02	낙엽송	
N03	기타 침엽수	
N04	활엽수	
N08	판독 불가	
N09	비산림	

산림 수종 학습용 데이터의 Fine annotation은 객체의 경계를 분류하는 정밀한 고품질 어노테이션으로, QGIS(Quantum GIS)을 활용하여 구축하였다.

<표 4> Find annotation 데이터 결과(예시)

항공영상(25cm)	항목분류	어노테이션 결과	
분류항목별 학습용 이미지 Sets 생성			
소나무	낙엽송	기타 침엽수	활엽수

\*개별 이미지 내에서 다수의 Features(폴리곤 객체) 구축


또한 Coarse annotation은 객체 내부를 분류하는 효율적인 어노테이션으로, 클라우드 기반 시스템을 통해 작업을 진행하였다.

### 3. 산림 수종 데이터 활용 인공지능 모델 개발

#### 3.1 인공지능 학습모델 선정

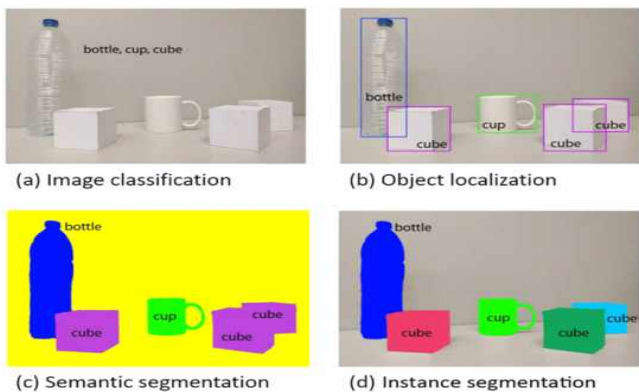
산림 수종 AI 모델은 각각의 AI 모델들을 평가하여 산림 수종 AI 학습용 데이터에 최적화된 모델을 선정하였고, 일반적인 semantic segmentation과 비교해서 shape 정보보다는 texture, color 정보 등 lower level feature를 활용하기 위한 연구와 클래스별 분포 차이에 따라 발생하는 성능의 편향성을 극복하는 연구를 진행하였다. [4-7]

Semantic segmentation은 이미지에 표현된 물체를 각 픽셀 레벨로 해당하는 클래스로 매칭 하는 것이 목적이며, 보통 dense prediction이라고도 한다.



(그림 2) semantic segmentation

물체 인식의 범주는 아래 그림과 같이 나뉘어 지며, 특히 semantic segmentation과 instance segmentation은 class별 분류이나 instance별 분류이냐에 따른 차이점이 있다.

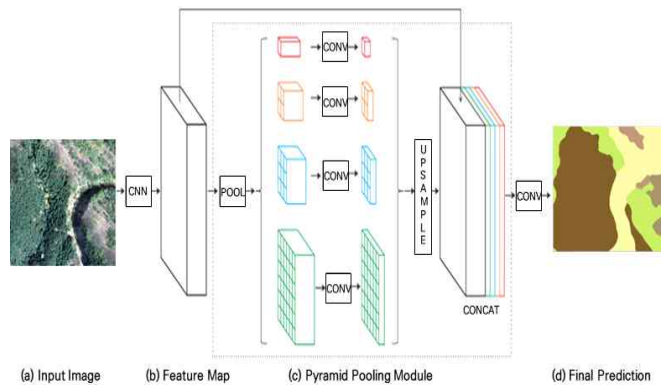


(그림 3) Semantic 및 Instance segmentation 차이

본 논문에서는 SOTA(State-of-the-Art) semantic segmentation 모델들을 overall accuracy로 성능 비교 평가하여, 산림 수종 데이터에 최적화된 모델인 DeepLabV3+를 선정하였다.

<표 5> 학습모델 비교


모델명	모델 특징
DeepLap V3+	<ul style="list-style-type: none"> <li>- 2015년 처음 발표된 DeepLab은 Atrous Spatial Pyramid Pooling을 사용하여 정밀도를 높임</li> <li>- 이후에 DeepLab v2, v3로 발전하여 2018년 DeepLab v3+이 PASCAL VOC 2012 데이터셋에서 89% mIOU의 높은 성능을 냄</li> </ul>
U-net	<ul style="list-style-type: none"> <li>- U 형태의 encoder-decoder 구조를 갖는 U-Net이 발표되며, encoder 구조에서의 디테일을 spatial dimension 축소로 인한 손실 정보를 decoder 구조에서 skip-connection을 통한 점진적 복원으로 보다 정교한 예측이 가능</li> </ul>
HRNet-OCR	<ul style="list-style-type: none"> <li>- 2020년 발표된 semantic segmentation에서 높은 성능을 나타낸 HRNet-OCR은 Cityscapes test 데이터셋에서 85.1% mIOU를 달성</li> <li>- 고정된 스케일들의 각각 모든 어텐션 마스크를 학습하는 것 대신 HRNet-OCR은 인접 스케일간 relative한 어텐션 마스크를 학습하는 hierarchical method를 채택</li> </ul>
SegNet	<ul style="list-style-type: none"> <li>- 최종 화소 단위 분류 레이어에 따라 하나의 인코더 네트워크와 관계된 디코더 네트워크가 존재</li> <li>- 인코더 네트워크는 13개의 covolutional 레이어로 구성</li> </ul>



(그림 4) DeepLabV3+구조

#### 3.2 알고리즘 품질검증 결과

본 논문에서는 학습데이터로 AI 알고리즘을 훈련 시켰을 때 목표로 했던 수준의 성능을 달성하는지 확인하는 유효성을 기준으로 성능 검증을 실시했다.[8-10]



(그림 5) 유효성 시험 환경 구성도

<표 6> 유효성 항목별 시험수행 결과

구분	내용
항목명	- 데이터 Semantic Segmentation 정확도
내용	- 산림 수종 항공 영상 모델(4개 클래스)성능 테스트 - 항공 영상 모델 클래스: 소나무, 낙엽송, 기타침엽수, 활엽수, 비산림 - 모사 영상 모델 클래스: 활엽수, 침엽수, 비산림 - 정확도 산정대상: Fine Annotation 데이터
지표	- 평균 Pixel accuracy - 테스트 셋에 속하는 이미지 영역 중 비대상지를 제외한 나머지 영역에서 정답인 픽셀 수를 대상지의 총 픽셀 수로 나눈 값
목표(기준)	- 평균 Pixel accuracy > 80% (수종 구분 > 75%, 침엽 구분 > 80%)
측정 산식	$Average\ Pixel\ Accuracy = \frac{1}{T} \sum_{i=1}^T \left( \frac{1}{N} \sum_{j=1}^N \left( \frac{\text{클래스 } j \text{의 정답 픽셀 수}}{\text{클래스 } j \text{의 총 픽셀 수}} \right) \times 100 \right)$ * N: 클래스 수 T: Test set 이미지 수
시험 결과	- 소나무/낙엽송 : 87.8% - 침엽수/활엽수 : 89.3%

산림 수종 AI 모델은 각각의 AI 모델들을 평가하여 산림 수종 AI 학습용 데이터에 최적화된 모델을 선정하였고, 일반적인 semantic segmentation과 비교해서 shape 정보보다는 texture, color 정보 등 lower level feature를 활용하기 위한 연구와 클래스별 분포 차이에 따라 발생하는 성능의 편향성을 극복하는 연구를 진행하였다.

**4. 결론 및 향후연구**

우리나라의 산림이 차지하는 산림면적은 2015년 기준 6,335천 ha로 산림이 차지하는 비율은 63.2%를 차지하고 있으며, 산림면적 비율은 OECD 국가 중 핀란드(73.1%), 일본(68.5%), 스웨덴 (68.4%)에 한국은 4위로 산림면적이 매우 높은 수준이다. 최근에서 산지 이용에 대한 수요가 급증하고, 수요 형태도 다양화되고 있어 무분별한 산지전용 행위가 증가하고 있다.

따라서, 본 논문에서는 산림 수종에 대한 학습용 데이터 구축 및 분석 알고리즘을 개발하였다. 이를 통해 AI를 이용한 시계열 분석을 통한 훼손 산지 의심 지역의 자동 추출이나 사용자의 전시기, 후시기 이미지를 이용한 변화탐지 서비스를 통해 산림변화지역 분류하고 해당 지역의 최적 조림수종 분석이 가능할 것으로 보인다.

향후 연구로는 전국단위의 산림 수종 학습용

데이터 구축을 통해 산림변화에 대한 다양한 국토환경 서비스로 확대하는 것이 요구된다.

**참고문헌**

[1] AI Hub, www.aihub.or.kr  
 [2] 인공지능 학습용 데이터셋 구축안내서, NIA, 2021  
 [3] 인공지능 학습용데이터 품질관리 가이드라인 v1.0, NIA, 2021  
 [4] Lobo Torres, D.; Queiroz Feitosa, R.; Nigri Happ, P.; Elena Cué La Rosa, Laura; Marcato Junior, J.; Martins, J.; Olã Bressan, P.; Gonçalves, W.N.; Liesenberg, V. Applying Fully Convolutional Architectures for Semantic Segmentation of a Single Tree Species in Urban Environment on High Resolution UAV Optical Imagery. Sensors. 2020, 20, 563.  
 [5] Andersson, V. Semantic Segmentation: Using Convolutional Neural Networks and Sparse Dictionaries. 2017.  
 [6] Long, J.; Shelhamer, E.; Darrell, T. Fully Convolutional Networks for Semantic Segmentation. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015, pp. 3431-3440.  
 [7] Zlateski, A., Jaroensri, R., Sharma, P., & Durand, F. On the importance of label quality for semantic segmentation. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018, pp. 1479-1487.  
 [8] Papa, J.P.; Falcão, A.X.; De Albuquerque, Victor Hugo C; Tavares, J.M.R. Efficient Supervised Optimum-Path Forest Classification for Large Datasets. Pattern Recognit. 2012, 45, 512-520.  
 [9] Hafemann, L.G.; Oliveira, L.S.; Cavalin, P. Forest Species Recognition using Deep Convolutional Neural Networks. In 2014 22nd International Conference on Pattern Recognition. 2014, pp. 1103-1107  
 [10] de Bem, P.P.; de Carvalho Junior, Osmar Abílio; Fontes Guimarães, R.; Trancoso Gomes, R.A. Change Detection of Deforestation in the Brazilian Amazon using Landsat Data and Convolutional Neural Networks. Remote Sensing. 2020, 12, 901.