

## 딥러닝 기반의 식생 모니터링 가능성 평가\*

김동우<sup>1)</sup> · 손승우<sup>2)</sup>

<sup>1)</sup>한국환경연구원·초빙연구원 · <sup>2)</sup>한국환경연구원·부연구위원

## Evaluation of the Feasibility of Deep Learning for Vegetation Monitoring\*

Kim, Dong-woo<sup>1)</sup> and Son, Seung-Woo<sup>2)</sup>

<sup>1)</sup>Korea Environment Institute, Visiting Researcher,

<sup>2)</sup>Korea Environment Institute, Research Fellow.

### ABSTRACT

This study proposes a method for forest vegetation monitoring using high-resolution aerial imagery captured by unmanned aerial vehicles(UAV) and deep learning technology. The research site was selected in the forested area of Mountain Dogo, Asan City, Chungcheongnam-do, and the target species for monitoring included *Pinus densiflora*, *Quercus mongolica*, and *Quercus acutissima*. To classify vegetation species at the pixel level in UAV imagery based on characteristics such as leaf shape, size, and color, the study employed the semantic segmentation method using the prominent U-net deep learning model. The research results indicated that it was possible to visually distinguish *Pinus densiflora* Siebold & Zucc, *Quercus mongolica* Fisch. ex Ledeb, and *Quercus acutissima* Carruth in 135 aerial images captured by UAV. Out of these, 104 images were used as training data for the deep learning model, while 31 images were used for inference. The optimization of the deep learning model resulted in an overall average pixel accuracy of 92.60, with mIoU at 0.80 and FIoU at 0.82, demonstrating the successful construction of a reliable deep learning model. This study is significant as a pilot case for the application of UAV and deep learning to monitor and manage representative species among climate-vulnerable vegetation, including *Pinus densiflora*, *Quercus mongolica*, and

\* 본 논문은 환경부의 환경기술개발사업(과제번호: 2021003360001)의 지원을 받아 한국환경연구원이 수행한 “ICT 기반 생태계 모니터링 기술 및 동식물 탐지 AI 알고리즘 개발(2023-021R)” 사업의 연구결과로 작성되었으며, 일부 재인용이 되었음을 알립니다.

**First author** : Kim, Dong-woo, Korea Environment Institute, Researcher,  
Tel : +82-44-415-7487, E-mail : dwkim@kei.re.kr

**Corresponding author** : Son, Seung-Woo, Korea Environment Institute, Research Fellow,  
Tel : +82-44-415-7821, E-mail : swson@kei.re.kr

**Received** : 27 October, 2023. **Revised** : 14 December, 2023. **Accepted** : 27 November, 2023

*Quercus acutissima*. It is expected that in the future, UAV and deep learning models can be applied to a variety of vegetation species to better address forest management.

**Key Words:** U-net, Remote sensing, UAV(Unmanned Aerial Vehicles), Species classification, *Pinus densiflora* Siebold & Zucc, *Quercus mongolica* Fisch. ex Ledeb, *Quercus acutissima* Carruth.

## I. 서론

탄소중립 실현을 위해 자연기반해법(Nature-based Solutions, NbS)이 주요 해결책으로 대두되고 있다. 자연기반해법이란 자연요소를 기반으로 하여 환경문제는 물론 사회, 경제 등 다양한 분야를 지속가능하게 하는 방법이라고 할 수 있다(Ministry of Environment, 2023). 자연기반해법 가운데 식생은 대표적인 탄소흡수원이자 생태계 기능 개선, 생물다양성 증대, 경관 개선 등 다양한 역할을 수행하는 자연요소이다. 하지만 기후변화로 인해 식생의 생장 저하, 병해충 확산 등의 원인으로 인해 서식지가 훼손되면서 체계적인 식생 관리가 요구되는 상황이다. 이에 산림청과 국립수목원에서는 기후변화에 대응하고자 기후변화 적응 대상식물종(Korean National Arboretum, 2010)과 기후변화 지표 산림종 모니터링 메뉴얼을 제시하였다(Korean National Arboretum, 2020).

또한 제3차 국가기후변화 적응대책에서 취약 식생의 개엽·개화·결실 등의 모니터링이 추진되는 등 식생 모니터링은 국가적으로 중요한 과제이다. 전통적인 식생 모니터링 방법은 현장조사를 통해 식생의 서식지와 구성, 그리고 건강성 등을 파악하는 것으로, 특히 산림 식생의 다층적 구조와 분포를 파악하기 위해서는 현장조사가 필수적이다. 하지만 현장조사는 기상, 지형 등의 환경적 특성으로 인해 조사 시간과 대상지가 제한적이며, 대상지의 범위가 넓을수록 조사비용이 증가하는 문제가 있다. 또한 현장조사자마다 식생조사 방법이 다각적이고 조사 결과가 다를 수 있기 때문에, 보다 객관적이고 과학적인 보완

방안이 필요하다.

이에 최근 식생 모니터링을 보완 방안으로 원격탐사 기법(Chen et al., 2019; Ali et al., 2021)이 많이 활용되고 있다. 위성영상 기반의 모니터링은 국토 전반을 시계열 단위로 분석이 가능하다는 장점을 가지고 있다. 최근에는 원하는 시간대에 사람이 접근하기 어려운 장소에서 고해상도의 영상을 취득할 수 있다는 장점을 갖고 있는 무인항공기를 활용하여 지형변화(Son et al., 2020), 도시공원의 열환경 변화(Kim et al., 2021), 해식애 변화(Yu et al., 2022), 그리고 해양 생물종 분포(Bycroft et al., 2019) 등 다양한 국토 환경분야에서 무인항공기가 적용되고 있다.

이처럼 기존의 위성영상과 항공기 촬영만으로는 제한되었던 시공간적 해상도를 극복하기 위해 무인항공기를 활용하고 있으며, 식생 모니터링 분야에서는 CNN(Convolutional Neural Network) 기반의 딥러닝 모델을 활용하여 식생 종 분류 및 분석 연구가 활발히 진행되고 있다. 특히 의미론적 분할(Semantic Segmentation) 모델을 활용하여 영상에서 픽셀단위로 식생 군락을 구분하여 식생종별 면적과 우점도 등을 산정하여 식생종의 분포 변화를 모니터링하는 연구가 최근의 주요 흐름으로 자리 잡고 있다(Kattenborn et al., 2021). 의미론적 분할 모델은 입력된 영상을 픽셀 단위로 특성을 훈련하고 예측할 수 있으며, 픽셀의 위치를 기억하여 식생 종류별 색상과 형태 등의 특성을 기반으로 식생 군락 분포 분석이 가능하다는 장점이 있다(Ferreira et al., 2020).

국내에서는 YOLO 등의 객체 탐지(Object detection) 딥러닝 모델을 활용하여 산림 식생을

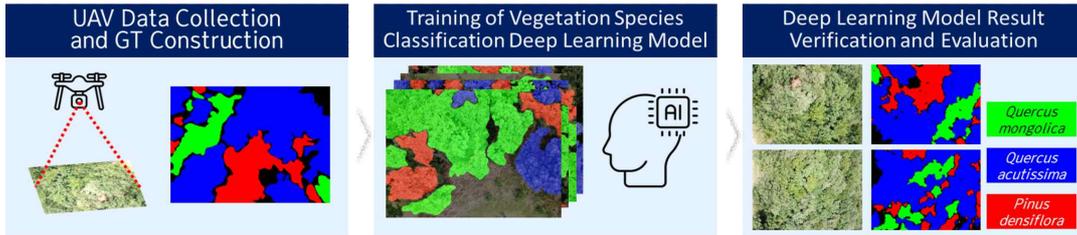


Figure 1. Research flow chart

분류하거나(Jang, 2021), 소나무 재선충 피해목 탐지를 목적으로 연구가 진행되고 있다(Park et al., 2021). 의미론적 분할 모델을 활용하여 산림 식생종을 탐지 및 분류하는 연구는 아직 일부종을 대상으로 제한적으로 시도되거나(Kim et al., 2022), 산림을 포함하여 토지피복을 분류하는 연구가 진행되고 있다(Lee et al., 2020).

국토환경을 평가 또는 모니터링을 위해 국토 환경성평가지도, 생태자연도 등의 공간데이터를 구축하여 다양한 분야에서 활용되고 있다. 또한 국토 자연환경을 주기적으로 조사하는 전국자연 환경조사와 환경영향평가 동식물 현황조사 등의 제도가 있다. 이 중 식생의 서식과 분포 현황 데이터는 가장 많이 활용되는 주요 평가 요소이며, 보다 효율적이고 객관적인 식생 조사 및 모니터링 방법이 요구되는 실정이다.

따라서 본 연구에서는 주요 산림 식생 모니터링 대상종을 선정하여 무인항공기를 기반으로 고해상도 영상을 취득하여 딥러닝 모델 학습용 정답지(Ground Truth: GT)를 구축하였고, 의미론적 분할 방식의 딥러닝 모델을 활용하여 픽셀 단위로 식생종별 특성을 훈련하여 식생종을 자동으로 탐지 및 분류하였다(Figure 1). 이러한 방법을 통해 식생종 모니터링의 정확도와 효율성을 확대하여 딥러닝 모델의 산림 식생 모니터링 활용 가능성을 모색하고자 한다.

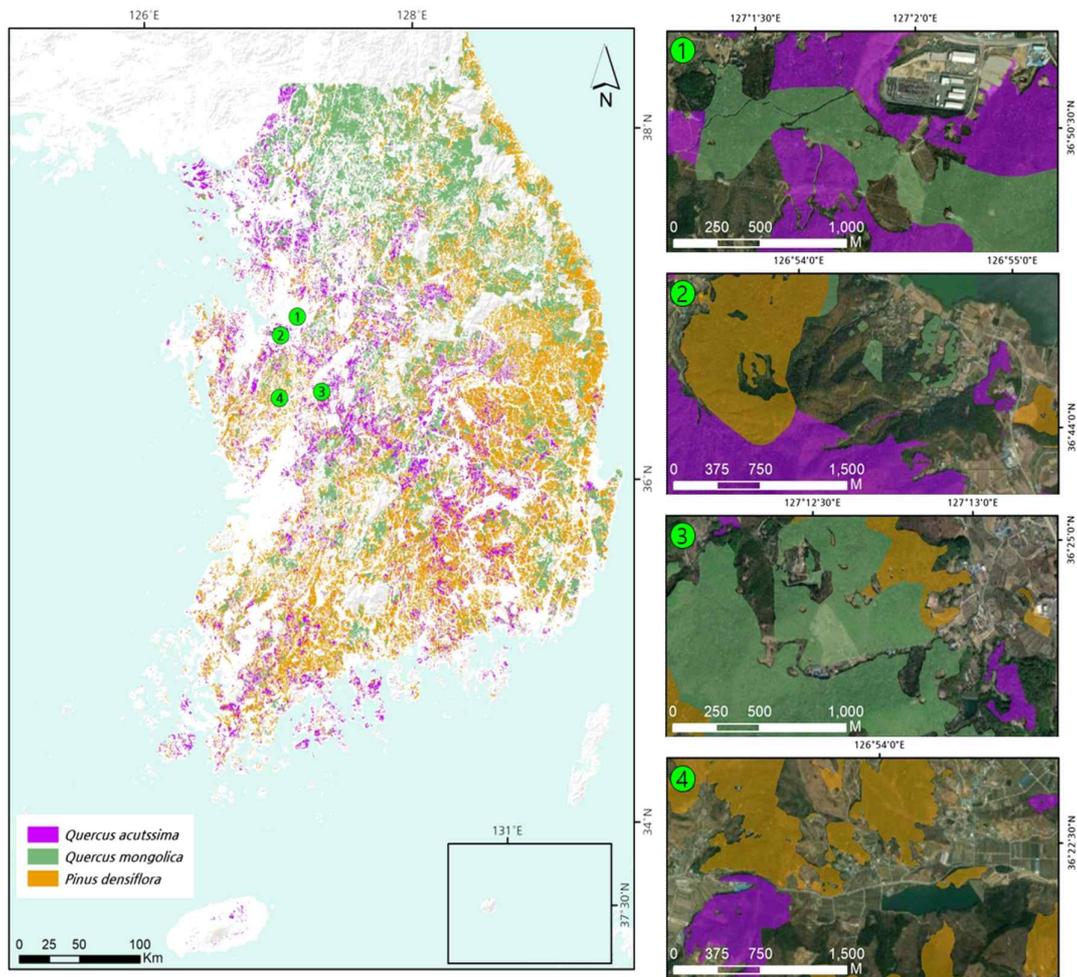
## II. 연구대상 및 방법

### 1. 연구지역 및 모니터링 대상

전국에 서식하고 있는 식생 가운데 가장 많은 군락을 형성하고 있는 대상종을 선정하기 위해 생태·자연도의 식생보전등급별 식물군락과 면적 현황을 분석하였다(Figure 2). 생태·자연도는 2023년 8월 22일 기준으로 공시된 자료를 활용하였다. 생태·자연도에서의 식물군락명 가운데 두 개 이상의 식생종이 혼생되어 있는 혼효림을 ‘최우점종-차우점종’ 형식으로 표기하는데, 최우점종은 60%이상의 우점비율을 차지하며 40%이 하인 경우에는 차우점종으로 판단한다(National Institute of Ecology, 2019). 그러나 두 식생종의 우점비율이 각각 50%인 경우에는 명칭을 나열할 때 두 식생종의 명칭을 순서 상관없이 기재된다(National Institute of Ecology, 2019). 따라서 본 연구에서는 혼효림 군락의 면적을 각 식생별로 50%로 일괄 할당하여 계산하였다.

식생보전등급 I, II, III등급에서 식생종별 면적 상위 10개를 산출한 결과, 신갈나무, 소나무, 굴참나무, 서어나무, 그리고 상수리무가 모든 등급에서 면적을 많이 차지하는 식생종으로 나타났다. 본 연구에서는 산림 식생 주요 모니터링 대상으로 현재 서식중인 식생 군락의 면적이 넓고 소나무재선충병과 참나무시들음병 등 산림병해충에 취약한 소나무와 신갈나무를 대상으로 선정하였다(Korea Forest Research Institute, 2010).

주기적인 현장 모니터링과 무인항공기 촬영을 위해 세종시와 충청남도를 대상으로 신갈나무와 소나무의 군락이 함께 분포하고 있는 대상지를 4곳을 선정하여 2023년 4월 25일과 26일에 걸쳐 현장조사를 실시하였다(Figure 2-①, ②, ③,



Grade 1		Grade 2		Grade 3	
Scientific name	Area(km <sup>2</sup> )	Scientific name	Area(km <sup>2</sup> )	Scientific name	Area(km <sup>2</sup> )
<i>Quercus mongolica</i>	196,928	<i>Quercus mongolica</i>	4,059,318	<i>Pinus densiflora</i>	17,534,255
<i>Pinus densiflora</i>	68,370	<i>Pinus densiflora</i>	2,895,002	<i>Quercus variabilis</i>	9,259,138
<i>Quercus variabilis</i>	42,851	<i>Quercus variabilis</i>	2,177,072	<i>Quercus mongolica</i>	7,176,089
<i>Carpinus laxiflora</i>	24,402	<i>Quercus serrata</i>	378,485	<i>Quercus acutissima</i>	5,247,255
<i>Fagus multinervis</i>	6,155	<i>Quercus acutissima</i>	225,054	<i>Pinus thunbergii</i>	2,671,082
<i>Quercus serrata</i>	6,152	<i>Pinus thunbergii</i>	100,893	<i>Quercus serrata</i>	1,156,923
<i>Quercus acuta</i>	5,253	<i>Carpinus laxiflora</i>	45,358	<i>Pinus rigida</i>	830,048
<i>Betula ermanii</i>	4,861	<i>Juglans mandshurica</i>	39,628	<i>Quercus aliena</i>	221,332
<i>Pinus thunbergii</i>	4,688	<i>Cornus controversa</i>	18,806	<i>Castanea crenata</i>	183,829
<i>Quercus acutissima</i>	3,779	<i>Quercus aliena</i>	13,121	<i>Acer okamotoanum</i>	18,763

**Figure 2.** Distribution of *Pinus densiflora*, *Quercus mongolica*, and *Quercus acutissima* Communities Based on the Ecosystem and Nature Map and Area by Conservation Class of Vegetation, and Four Field Survey Sites(①: 416 Songchon-ri, Eumbong-myeon, Asan-si, Chungcheongnam-do, ②: San36-8 Sinyu-ri, Dogo-myeon, Asan-si, Chungcheongnam-do, ③: San65-1 Maam-ri, Banpo-myeon, Gongju, Chungcheongnam-do, ④: San114-4 Jeokgok-ri, Jangpyeong-myeon, Cheongyang-gun, Chungcheongnam-do.)

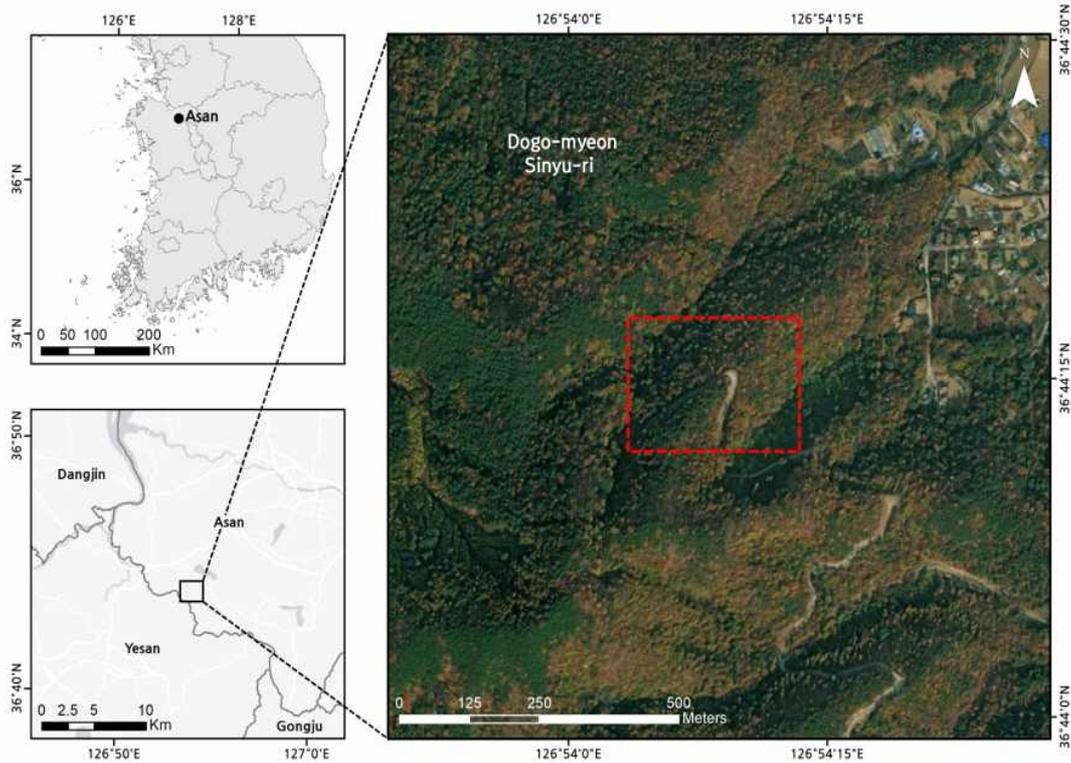


Figure 3. Study area

④). 현장조사 결과 아산시 도고면 도고산 일대를 제외한 나머지 대상지에서는 대상종 가운데 하나인 신갈나무가 발견되지 않거나 졸참나무와 갈참나무가 주로 분포하는 것으로 나타났다. 따라서 본 연구에서는 대상종의 군락이 잘 형성되어 있는 충청남도 아산시 도고산 일대를 대상지로 선정하였으며(Figure 3), 4월 27일, 28일, 6월 13일, 14일 총 4일간 현장조사를 통해 대상종의 위치와 분포를 확인하였다. 현장조사 결과 신갈나무와 같은 참나무목에 속하는 상수리나무의 서식이 추가적으로 확인되어 최종적으로 소나무와 신갈나무, 그리고 상수리나무를 본 연구에서의 모니터링 대상으로 선정하였다.

2. 무인항공기 기반 식생 영상 촬영

본 연구에서는 연구대상지에 분포하는 식생의 개엽이 완료되고 풍력과 풍속 그리고 운량 등의

기상 조건이 양호하였던 2023년 6월15일 오전 11시부터 약 40분 동안 연구 대상지 일대 약 10,000㎡를 대상으로 약 40분 동안 실시하였다. DJI社의 Mavic Pro와 자체 짐벌 광학카메라를 사용하여 식생종별 잎과 줄기의 형태 이미지를 취득하였으며, 상세정보는 Table 1과 같다.

Table 1. Information of UAV and camera(RGB)

Model	Mavic Pro
Weight	743g
Maximum flight time	27 minutes
Maximum flight speed	65 km/h
Camera FOV	78.8°
Camera Shutter speed	8~1/8000s
Photo Resolution(pixels)	4000 × 3000
ISO	100-1600 (picture)

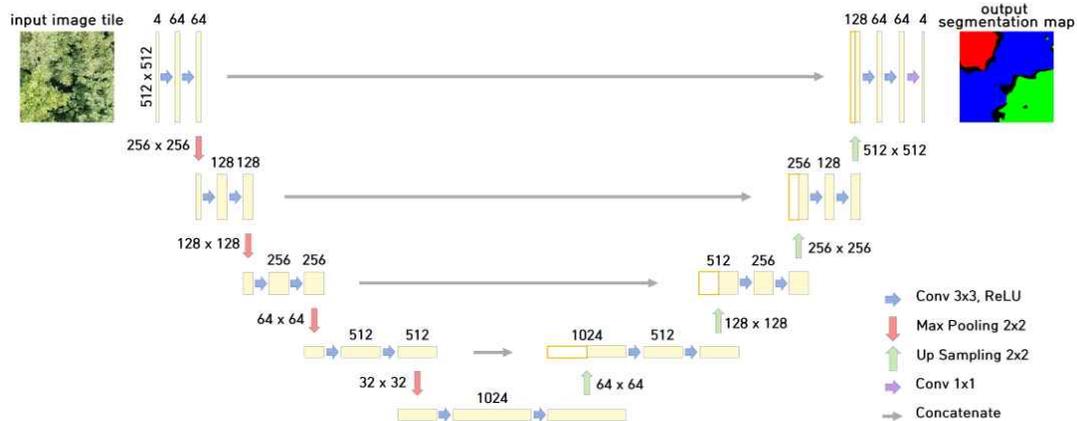


Figure 4. U-net architecture

식생의 잎과 줄기, 그리고 캐노피의 형태를 고 해상도 영상으로 촬영하면서 최대한의 넓은 면적을 촬영하기 위해 비행고도를 15m로 설정하였으며, 촬영 중복도는 횡·종중복도 70%로 비행 및 촬영을 실시하였다. 무인항공기 비행 및 영상 촬영에는 Pix4D社의 Pix4d-capture를 사용하여 촬영을 실시하였다. 촬영된 영상의 위치 정확도를 보정하기 위해서는 촬영대상지에 지상기준점을 측량해야 하지만, 식생이 우거지고 개방된 공간이 부족한 연구대상지의 환경적 제약으로 인해 해당 과정은 생략하였다.

### 3. 딥러닝 모델 구성

본 연구에서는 이미지에서 식생의 잎과, 줄기 등의 형태를 종별로 구분하여 최종적으로 대상 종별 분포를 파악하기 위해 이미지를 픽셀 단위로 구분하여 특정 객체의 경계선을 따라 분류하는 의미론적 분할 모델을 활용하였다.

본 연구에서는 U-net을 기반으로 학습을 수행하였다(Figure 4). U-net은 의료 영상 분석 분야에서 세포, 조직 등 생물학적 구조 영상에서 객체의 영역을 분할하기 위해 제시된 합성곱 신경망(Convolution Neural Networks: CNN)이다. U-Net의 가장 주요한 특징은 아키텍처가 'U' 형태로 이루어져 있어 이미지를 입력받는 encoder

부분과 예측 이미지를 출력하는 decoder 부분으로 나뉘는 것이 특징인데, encoder 부분에서는 전통적인 CNN과 유사하게 입력된 이미지를 작은 공간 해상도로 축소시켜 특징을 추출하고, decoder 부분에서는 spatial dimension 축소로 인한 손실 정보를encoder 부분에서 추출된 특징을 skip-connection을 통해 점진적으로 복원시켜 객체의 경계를 잘 보존하여 예측하는 장점을 가지고 있다. 또한 U-Net은 적은 양의 학습 데이터로 학습 및 추론에 효과적이며 충분한 양의 학습 데이터가 제한된 조건에서 학습과 추론에 적절한 딥러닝 모델이다(Ronneberger et al., 2015).

### 4. 딥러닝 모델 학습 및 검증 데이터 구축

딥러닝 모델 학습 및 검증 데이터 구축을 위해 영상에서 모니터링 대상종을 표시하는 레이블링(Labelling) 작업을 실시하였다. 무인항공기로 촬영된 영상에서 상수리나무와 소나무, 그리고 신갈나무의 영역을 각각 다른 색상으로 표시하였으며, 나머지 식생과 도로는 배경으로 구분하여 총 4개의 클래스를 구분하여 레이블링을 진행하였다. 레이블링 작업은 오픈소스 이미지 편집 프로그램인 GIMP 2.10을 사용하였다. 최종적으로 레이블링이 GT와 원본이 되는 영상을 세트 구성하여 데이터 세트를 구축하였다.

구축된 데이터 세트는 무인항공기로 촬영한 영상을 기반으로 식생종 분포를 분석하여 4개 구역으로 구분하였으며(Figure 5), 전체 무인항공기 영상 240장 가운데 구역별로 중복되는 영상을 제외하고 135장의 영상을 선별하였다. 각 클래스별로 정확도를 산출하여 검증하기 위해 135장의 영상 가운데 모니터링 대상종이 혼재되어 분포하고 있는 연구지역 동쪽의 4구역을 대상으로 촬영된 영상 31장을 딥러닝 모델의 추론 데이터로 활용하였으며, 나머지 3개 구역에서 촬영된 104장의 영상을 학습 데이터로 사용하였다.

구축한 학습 및 검증 데이터는 딥러닝 모델에서의 원활한 학습 및 추론을 위해 약 25%의 중복률을 설정하여 512×512 픽셀 크기로 분할하였으며, 최종적으로 GT 기준 학습 데이터 7,780장과 추론 데이터 2,420장을 활용하였다. 분할된 GT의 학습 및 추론 데이터에서 레이블된 대상종과 배경의 픽셀 개수 비율은 Table 2와 같다.

**Table 2.** Target species GT data ratio(%)

Target	Train	Test
<i>Quercus mongolica</i>	39.51	17.07
<i>Quercus acutissima</i>	15.51	46.00
<i>Pinus densiflora</i>	13.47	11.70
Background	31.51	25.23

### 5. 딥러닝 모델 학습 및 검증

본 연구에서는 딥러닝 모델을 학습시키고 이를 검증하기 위해 워크스테이션 기반의 개발환경을 구축하였다. 딥러닝 모델 개발 및 구동은 Python을 기반의 딥러닝 라이브러리인 Pytorch를 활용하였다. 딥러닝 모델의 최적화를 위한 학습조건(Hyper parameter)으로는 딥러닝 모델의 예측값과 GT간의 차이를 평가하기 위한 Loss Function과 Loss Function을 최소화하기 위한 가중치 조절하는 역할을 하는 Optimization Algorithm, 그리고 Optimization Algorithm에서



**Figure 5.** Division of study area zones

가중치를 조정하는 방식을 제어하는 Learning rate가 있다. 또한 학습 데이터 세트의 학습 반복 횟수인 Epoch와 한 번의 학습에 입력되는 데이터의 개수인 batch size를 설정해야한다. Table 3는 본 연구의 딥러닝 모델의 개발환경과 최적으로 구성된 학습조건이다.

**Table 3.** HW/SW and hyper parameter

HW	OS	Ubuntu 20.04
	Memory	DDR4 256GB
	GPU	NVIDIA GeForce RTX3090
SW	Programming language	Python 3.8.12
	Frame work	CUDA 11.4 Pytorch 1.13
Hyper parameter	Loss Function: OHEM Cross Entropy Optimization Algorithm: Adam Learning Rate: 0.001 Epoch: 70 Batch Size: 24	

최적으로 구축된 딥러닝 모델은 Semantic Segmentation 모델의 정확도를 평가하는 지표 가운데 전체 픽셀 중 올바르게 분류된 픽셀의 비율인 Pixel Accuracy와 예측된 픽셀의 영역과 실제 픽셀 영역의 교집합을 전체 영역의 합으로 나눈 값인 IoU(Intersection over Union), 그리고 IoU를 클래스별 빈도로 가중 평균한 FIoU(Frequency-weighted IoU)를 활용하여 클래스별

**Table 4.** Pixel count and prediction ratio for the class between the GT and U-Net predicted results.

class		Pixel count		Prediction Ratio(%)
		GT	U-net	
<i>Pinus densiflora</i>	A	2,210,581	2,401,666	108
	B	791,211	891,628	112
<i>Quercus mongolica</i>	A	1,434,318	1,514,593	105
	B	1,485,607	1,618,298	108
<i>Quercus acutissima</i>	A	6,448,332	6,688,553	103
	B	5,252,145	5,631,352	107
Background	A	1,906,769	1,395,188	73
	B	4,471,037	3,858,722	86

로 정확도 지표를 평가하여 비교 분석을 실시하였다. Pixel accuracy는 0부터 100 사이의 백분율로 나타내며 100에 가까울수록 높은 정확도를 의미하며, IoU는 0부터 1사이의 백분율로 나타내는데 1에 가까울수록 높은 정확도를 의미한다.

### III. 연구결과

#### 1. 딥러닝 모델 학습 및 검증 결과

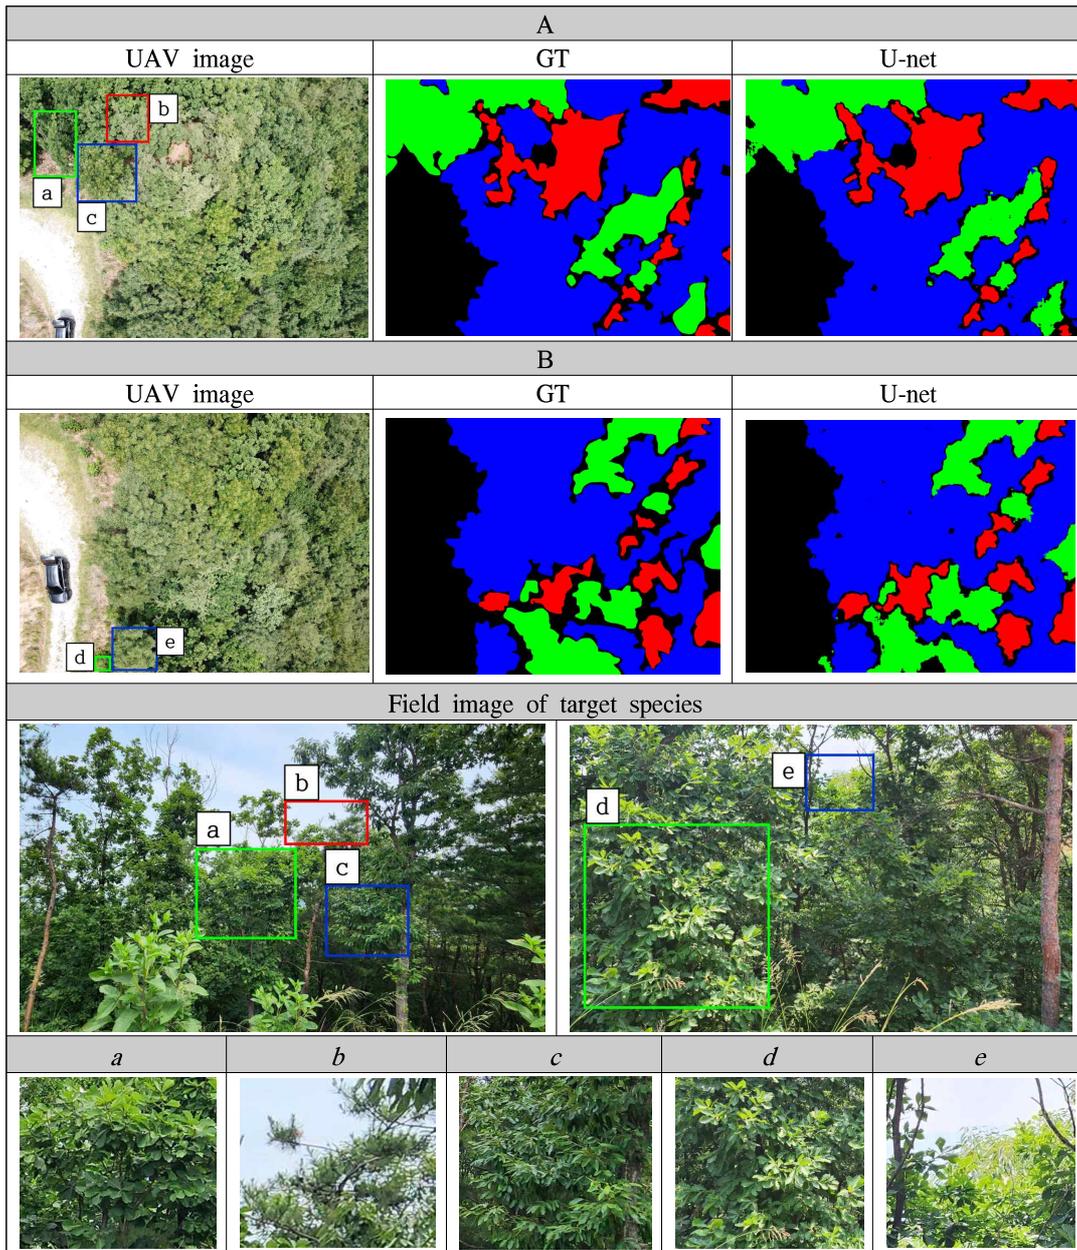
본 연구에서는 U-net 모델을 활용하여 클래스별로 예측 결과와 GT를 Pixel 단위로 비교하였으며, 이를 토대로 Pixel accuracy와 IoU를 산출하였다(Table 4).

전체 클래스 평균 Pixel accuracy는 92.60으로 산출되었다. Pixel accuracy가 가장 높은 클래스는 상수리나무로 94.01이었으며, 소나무가 92.03, 그리고 신갈나무가 89.22였다. 클래스 가운데 IoU가 가장 높았던 것은 상수리나무로 0.86이었으며, 신갈나무와 소나무는 각각 0.77과 0.76으로 비슷한 수치로 나타났다. 전체 클래스 mIoU는 0.80으로 준수한 정확도로 나타났으며, FIoU 또한 0.82로 높게 나타났다. 모든 정확도 지표에서 학습데이터가 비교적 적었던 상수리나무의 정확도가 가장 높게 나타났으며, 이는 상수리나무의 잎의 색상과 수관 형태가 소나무와 신갈나무와 비교하여 딥러닝 모델에 특성이 보다 뚜렷하게 학습된 것으로 추측할 수 있다.

무인항공기 원본 영상을 기반으로 식생 군락 분포 분석을 위한 딥러닝 모델의 활용성을 평가하기 위해 추론 데이터로 활용된 4구역의 무인항공기 원본 영상을 구축된 딥러닝 모델에 입력하여 예측하였다. 이 가운데 딥러닝 모델에 분할하지 않은 원본 영상을 예측한 결과와 GT 예시는 Figure 6이며, Table 5는 GT와 딥러닝 모델 예측 결과의 대상종 픽셀 개수와 예측 비율을 산정한 결과이다.

예측 결과, 일부 소규모의 식생은 배경이나 주변의 다른 식생으로 예측되는 오류가 있었지만, 대부분의 식생 수관폭 경계부분이 GT와 부합하는 형태로 예측되었다. Figure 7-a, b, c와 같이 세 가지 식생종이 혼재되어 있는 곳에서도 현장에서 확인된 식생종의 경계와 딥러닝 모델의 예측 결과가 유사한 것을 확인 할 수 있었다.

식생 내부에 개방된 나지와 도로는 배경으로 잘 예측되었지만, 식생 내부의 그림자 영역은 GT와 비교하였을 때 주변에 위치한 식생들로 예측되어 식생종의 수관 면적이 과대 예측된 것으로 나타났다. 예측한 영상의 픽셀 개수를 산정한 결과에서도 모든 식생종이 과대 예측되었다. 상수리나무가 3%로 가장 적게 과대 예측되었으며, 신갈나무는 5%로 과대 예측되었고, 소나무가 최대 8%까지 과대 예측되는 것으로 나타났다. 이는 학습 데이터를 구축 과정에서 식생종 군락 경계가 모호한 지역을 배경으로 설정한 영역이, 딥



**Figure 7.** A, B: UAV image, GT data, and U-net output result (Red: *Pinus densiflora*, Green: *Quercus mongolica*, Blue: *Quercus acutissima*). a, b, c, d, e: Field image of target species (a, d: *Quercus mongolica*, b: *Pinus densiflora*, c, e: *Quercus acutissima*)

러닝 모델 결과에서는 특정 식생종 균락으로 예측하면서 과대 예측된 것으로 판단된다.

추후 전체적인 딥러닝 모델의 정확도를 향상시키기 위한 방안으로 학습 데이터의 증강과 딥

러닝 모델 아키텍처 개선을 고려할 수 있다.

추가적인 영상 촬영과 GT 데이터 구축뿐만 아니라 크기 조정, 회전, 색상 변환 등의 데이터 증강기법 기법을 활용하여 본 연구에서 구축한

딥러닝 모델의 성능을 향상시킬 수 있을 것으로 예상된다.

**Table 5.** Prediction accuracy results of the deep learning model

class	Pixel accuracy(%)	IoU(%)	
<i>Quercus mongolica</i>	89.22	0.77	
<i>Quercus acutissima</i>	94.01	0.86	
<i>Pinus densiflora</i>	92.03	0.76	
Total	92.60	mIoU(%)	FIoU(%)
		0.80	0.82

딥러닝 모델의 활용성을 높이기 위한 방안으로는 시기별 영상데이터의 추가 확보와 식생종 확대 적용을 제시할 수 있다. 본 연구에서는 한 시기의 촬영을 통해 데이터를 구축하였기 때문에, 다른 시기에 촬영된 영상을 기반으로 식생종을 모니터링하기 위해서는 추가적인 영상과 GT 데이터 구축이 요구된다. 활엽수인 신갈나무와 상수리나무는 잎의 형태와 색상이 다른 계절에 따라 변화하므로 모든 시기에 적합한 딥러닝 모델을 구축하기 위해서는 계절별 영상이 필요한데, 특히 신갈나무의 잎의 형태는 갈참나무와 유사한 형태를 나타내며, 상수리나무와 굴참나무도 잎의 형태만으로는 동정이 어려워 딥러닝 학습 데이터 구축 시에는 추가적인 현장조사가 병행되어야 할 것이며, 본 연구에서 활용한 광학 카메라 센서 이외에 다분광 카메라 센서를 활용하여 잎의 형태와 크기가 비슷한 식생을 분류하는 것을 제안할 수 있다. 또한 본 연구에서는 고도 15m에서 무인항공기 영상을 촬영하여 GT를 구축하고, 영상에서 대상종을 자동으로 분류하는 딥러닝 모델을 구축하였기 때문에 비행고도와 카메라 센서의 성능 차이로 인해 본 연구에서

활용한 영상과 비교하여 해상도가 크게 차이나는 영상은 딥러닝 모델에 적용하기 어려울 것으로 판단된다.

#### IV. 결론

본 연구는 산림 식생의 효율적인 모니터링과 관리를 위한 방안으로 무인항공기 기반의 고해상도 광학영상과 딥러닝 모델 기반의 자동 탐지 방법을 제안하였다. 모니터링 대상종은 우리나라 전 지역에서 가장 넓은 분포로 서식하고 있으며, 기후변화 모니터링 지표종 및 병해충 피해의 주요종인 소나무와 신갈나무로 선정하였으며, 연구대상지 현장조사 결과 넓게 서식하고 있었던 상수리나무를 추가하였다.

비행고도 15m에서 고해상도 영상을 취득한 결과 식생의 줄기와 잎 등의 형태적 특징을 기반으로 대상종의 분포 경계 구분이 가능하였다. 딥러닝 모델은 영상에서 픽셀 단위로 식생의 경계를 분류하기 위해 Semantic Segmentation인 U-net을 활용하였다. 딥러닝 모델 학습을 위한 GT 구축은 모니터링 대상종에 배경을 추가하여 총 4개의 클래스로 GT를 구축하였으며, 512×512 픽셀 크기로 분할하여 7,780장의 학습 데이터와 2,420장의 추론 데이터를 딥러닝 모델의 학습과 정확도 검증 단계에서 활용하였다. 정확도 검증 결과 대상종 클래스 평균 Pixel accuracy는 92.60이었으며, 클래스 가운데는 상수리가 나무가 94.21로 가장 높았다. mIoU과 FIoU 또한 0.80과 0.82로 나타났으며, 상수리나무가 0.86으로 가장 높은 정확도로 나타났다.

본 연구에서는 무인항공기를 기반의 고해상도 영상을 활용하였지만, 동일 지역의 항공사진과 위성영상을 함께 학습하여 다양한 시기의 시계열 식생 모니터링이 가능한 딥러닝 모델을 추후 연구로 제안하고자 한다. 특히 식생종별 개엽 및 개화시기에 따라 계절별 식생종의 영상을 수집하여 이를 구분할 수 있는 딥러닝 모델을 구축한

다면 어떤 시기에서도 산림 식생을 자동으로 분류할 수 있을 것으로 기대된다.

원격탐사 기반의 영상 촬영을 통해 산림 식생종을 자동으로 탐지하고 군락면적을 분류하는 딥러닝 모델은 기존의 산림 식생 모니터링 방법을 보완하는 방법론으로 활용될 수 있을 것으로 판단된다. 특히 정기적인 영상 촬영을 통해 산림 식생의 훼손지를 탐지하고, 복원을 통해 변화하는 산림 식생 분포와 면적을 객관적으로 산출하는 데 기여할 수 있다. 하지만 하층 식생의 경우 영상 촬영이 제한되며, 수목 병충해 의해 잎이 훼손된 식생은 광학영상으로 동정이 제한된다. 이후 연구에서는 다분광 카메라, 라이다 기반의 식생 데이터 구축을 통해 식생별 수고, 수관, 수형 등의 특성을 학습하는 딥러닝 모델 검증은 시도할 필요가 있다.

### References

- Ali, S., Haixing, Z., Qi, M. Liang, S., Ning, J., Jia, Q., & Hou, F. (2021) Monitoring drought events and vegetation dynamics in relation to climate change over mainland China from 1983 to 2016. *Environ Sci Pollut Res* 28, 21910–21925.
- Bycroft, R., Leon, J. X., & Schoeman, D. (2019). Comparing random forests and convoluted neural networks for mapping ghost crab burrows using imagery from an unmanned aerial vehicle. *Estuarine, Coastal and Shelf Science*, 224, 84-93.
- Chen, Y., Guerschman, J. P., Cheng, Z., & Guo, L. (2019). Remote sensing for vegetation monitoring in carbon capture storage regions: A review. *Applied Energy*, Volume 240, 312-326.
- Ferreira, M. P., Almeida, D., Papa, D., Minervino, J., Veras, H., Formighieri, A., Santos, C., Ferreira, M., Figueiredo, E., & Ferreira, E. (2020). Individual tree detection and species classification of Amazonian palms using UAV images and deep learning. *Forest Ecology and Management*, 475, 118397.
- Jang, K., (2021). A Study on the Deep Learning-based Tree Species Classification by using High-resolution Orthophoto Images. *Journal of the Korean Association of Geographic Information Studies*, 24(3), 1-9. (in Korean)
- Kattenborn, T., Eichel, J., & Fassnacht, F. E. (2019). Convolutional Neural Networks enable efficient, accurate and fine-grained segmentation of plant species and communities from high-resolution UAV imagery. *Scientific reports*, 9(1), 17656.
- Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS journal of photogrammetry and remote sensing*, 173, 24-49.
- Kim, D., Yu, J., Yoon, J., Jeon, S., & Son, S. (2021). Comparison of accuracy of surface temperature images from unmanned aerial vehicle and satellite for precise thermal environment monitoring of urban parks using in situ data. *Remote Sensing*, 13(10), 1977.
- Kim, S.H., Kwon, K.W., & Kim H.J. (2022). A Study on Orthogonal Image Detection Precision Improvement Using Data of Dead Pine Trees Extracted by Period Based on U-Net model. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*. 40(4), 251-260. (in Korean)
- Korea Forest Research Institute. (2010). Research

- on the Occurrence and Ecological Characteristics and Control of Oak Wilt Disease. (in Korean)
- Korean National Arboretum. (2010). 300 Target Plants Adaptable to Climate Change in the Korean Peninsula. Korea National Arboretum, Pocheon, Korea. 492. (in Korean)
- Korean National Arboretum. (2020). Climate Change Indicator Forest Plant Seasonal Observation Monitoring Manual, Pocheon, Korea. 262. (in Korean)
- Lee, SH., Lee, M. (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. (in Korean)
- Ministry of Environment. (2023). Study on the Selection Criteria for National Environment Green Restoration Candidate List. (in Korean)
- National Institute of Ecology. (2019). Guidelines for the 5th National Ecosystem Survey. (in Korean)
- Park, Ju., Lee, M., & Choi, SY. (2021). Analysis of Trees Damaged by Pine Wilt Nematodes Using Unmanned Aerial Images. *Journal of the Korean Cadastre Information Association*, 23(2), 78-86. (in Korean)
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention*, 234-241.
- Son, S. W., Kim, D. W., Sung, W. G., & Yu, J. J. (2020). Integrating UAV and TLS approaches for environmental management: A case study of a waste stockpile area. *Remote Sensing*, 12(10), 1615.
- Yu, J.J., Kim, D. W., Lee, E. J., & Son, S. W. (2022). Mid-and Short-Term Monitoring of Sea Cliff Erosion based on Structure-from-Motion (SfM) Photogrammetry: Application of Two Differing Camera Systems for 3D Point Cloud Construction. *Journal of Coastal Research*, 38(5), 1021- 1036.