

해안사구 식생의 보전 및 관리를 위한 딥러닝 기반 모니터링*

김동우¹⁾ · 구자운¹⁾ · 홍예지¹⁾ · 김세민²⁾ · 손승우³⁾

¹⁾한국환경연구원 연구원 · ²⁾롤루랩 수석연구원 · ³⁾한국환경연구원 부연구위원

Deep learning-based monitoring for conservation and management of coastal dune vegetation*

Kim, Dong-woo¹⁾ · Gu, Ja-woon¹⁾ · Hong, Ye-ji¹⁾ · Kim, Se-Min²⁾ and Son, Seung-Woo³⁾

¹⁾Korea Environment Institute, Researcher,

²⁾LULULAB INC, Principal Engineer,

³⁾Korea Environment Institute, Research Fellow.

ABSTRACT

In this study, a monitoring method using high-resolution images acquired by unmanned aerial vehicles and deep learning algorithms was proposed for the management of the Sinduri coastal sand dunes. Class classification was done using U-net, a semantic division method. The classification target classified 3 types of sand dune vegetation into 4 classes, and the model was trained and tested with a total of 320 training images and 48 test images. Ignored label was applied to improve the performance of the model, and then evaluated by applying two loss functions, CE Loss and BCE Loss. As a result of the evaluation, when CE Loss was applied, the value of mIoU for each class was the highest, but it can be judged that the performance of BCE Loss is better considering the time efficiency consumed in learning. It is meaningful as a pilot application of unmanned aerial vehicles and deep learning as a method to monitor and manage sand dune vegetation. The possibility of using the deep learning image analysis technology to monitor sand dune vegetation has been confirmed, and it is expected that the proposed method can be used not only in sand dune vegetation but also in

* 본 논문은 환경부의 환경기술개발사업(과제번호: 2021003360001)의 지원을 받아 한국환경연구원이 수행한 “ICT 기반 생태계 모니터링 기술 및 동식물 탐지 AI 알고리즘 개발(2022-011R)” 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, Email: swson@kei.re.kr

Received : 27 October, 2022. **Revised** : 25 November, 2022. **Accepted** : 22 November, 2022

various fields such as forests and grasslands.

Key Words : Coastal sand dune, Vegetation monitoring, Deep learning, U-net, UAV(unmanned aerial vehicles)

I. 서 론

해안사구는 해변의 모래가 바람에 의해 이동 및 퇴적되어 발달한 지형으로 해안과 내륙의 접이 지대에 위치한 지형으로 환경, 생태景觀적으로 중요한 자연환경 자산이다(Giglio et al., 2019). 폭풍, 홍수, 해일 등의 자연재해로부터 내륙의 피해를 완화시킬 수 있는 자연제방의 역할과 함께 생태계 중요성 또한 주목받고 있다(Ettrich et al., 2018). 특히, 해안사구에 자생하고 있는 사구 식생들은 탄소흡수 기능이 뛰어난 'Blue-carbon'으로 불리며 탄소중립시대에 보전해야 할 주요한 생태계로, 다양한 연구가 수행되고 있다. 그러나 관광자원, 항만 등의 개발사업과 모래 채취, 외래종 침입으로 인해 생태계 변화와 더불어 지형적 파괴가 나타나고 있다.

해안사구에 자생하는 사구 식생은 해변, 전사구, 사구저지 등 해안사구 미지형에 따라 다양한 식물 종이 분포하고 있어 현장조사 시 전수 조사가 필요하며, 사구 식생의 분포와 생장은 계절별 모래의 이동과 강수에 따라 변화하기에, 시기별 현장조사가 필요한 실정이다. 이에, 국내에서는 전국자연환경조사, 습지 모니터링, 자연자원 모니터링 등 해안사구에 대한 생태계 조사가 수행되고 있다. 그러나 지형 및 지질 특성상 현장조사가 제한적이고 대상지의 범위가 넓을수록 비용이 급격히 증가하는 문제가 제기되고 있다(Song et al., 2007).

이를 보완하기 위한 각 지역 특성에 적합한 조사지침 작성 등의 정량적 자료 수집이 요구되고 있다[6]. 또한, 효율적인 현장조사를 위한 ICT(Information and Communications Technology) 기반의 식생 모니터링 기술이 발달하고 있다. 특히 무인항공기를 이용하여 고해상도의 영상을 취득하여

국지적 식생 변화와 지형적 변화를 탐지하는 연구가 다수 수행 중이다(Laporte-Fauret et al., 2020). 또한, CNN(Convolutional Neural Network) 등의 인공지능을 이용하여 식생의 변화를 예측하고 분석하는 연구가 최근 발표된 바 있다(Villoslada et al., 2020). 최근에는 CNN보다 발전된 형태의 의미론적 분할(semantic segmentation) 모델을 활용하여 식생 군락의 면적과 우점도 등을 산정하여 대상종의 분포 변화를 예측한 연구가 주요 흐름으로 자리 잡고 있다(Soltani et al., 2022). 그러나 해안사구의 식생의 중요성이 두드러짐에도 불구하고 해안사구와 사구 식생을 대상으로 한 연구가 미비한 실정이다.

이에 본 연구에서는 신두리 해안사구를 연구지역으로 설정하고, 해당 지형에 서식하는 염생식물을 모니터링하기 위한 방법으로 무인항공기와 딥러닝 활용한 예측 모델을 제안한다. 향후 본 연구에서 제안하는 모니터링 방식을 환경영향평가 또는 자연환경조사에서 활용할 수 있는 가이드라인으로 제시하고자 한다.



Figure 1. 연구대상 지역 위성영상

II. 연구방법

1. 연구지역 및 모니터링 대상

연구대상지는 천연기념물 제431호 충청남도

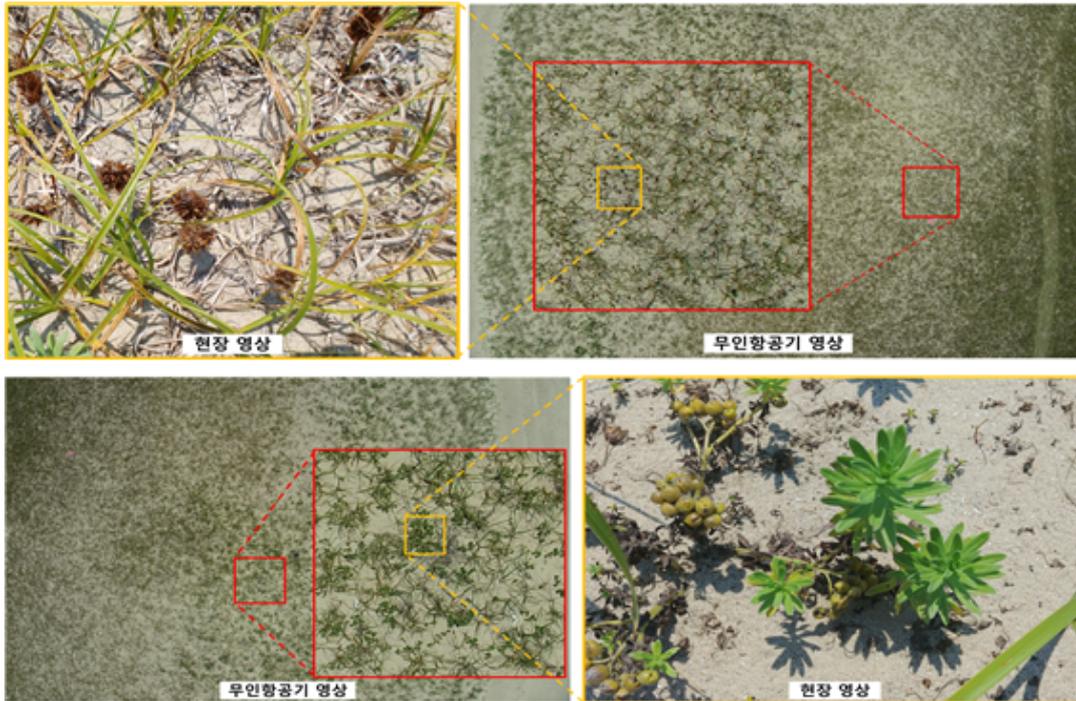


Figure 2. 통보리사초(상단)와 모래지치(하단)의 무인항공기 및 현장 사진

태안군 원북면 신두리 해안사구의 일부 지역으로 설정하였다(그림 1). 해안사구는 해변 혹은 모래펄의 모래가 바람에 날려 그 배후로 운반, 퇴적됨으로써 발달하는 해안퇴적 지형이다. 파랑과 바람의 작용이 탁월한 모래해안에서는 해변과 해안사구가 서로 결부되어 발달하는데, 신두리 지역의 해안사구는 이러한 발달이 크게 나타나는 대표적인 사구 지형이다(Song et al., 2005). 또한, 신두리 해안사구는 아까시나무 군락이 대규모로 분포하여 2012년, 2014년 2016년에 걸쳐 식생 제거가 이루어졌으며, 비사구성 외래수종과 초본류 제거에 따라 사구식물 군락과 건생식물 군락의 변화가 나타나는 자연 천이 단계가 일어나고 있다(Lee et al., 2020, Kahng et al., 2006). 2021년부터는 사구 식생의 정착과 성장을 도모하기 위해 전사구와 이차사구에 걸쳐있는 산책로와 지표상의 식생을 제거하는 복원사업이 진행 중이다.

신두리 해안사구는 해안선 길이 3 ~ 3.4km, 해

안선에서 구릉지까지 최대 1.3km 너비의 크기로 발달한 지형으로, 사구생태계 등의 자연환경이 원형에 가깝게 보전되어있는 생태적 가치가 높은 지역이다(Kim et al., 2021). 특히, 전사구 지형에 대해서는 갯그렁, 통보리사초, 모래지치 등의 사구 식생이 우점하고 있으며, 이러한 사구 식생은 모래 채집의 역할을 하여 사구의 성장에 기여하는 효과를 가지고 있다. 특히 갯그렁은 해안사구의 선구종으로 근경을 수직, 수평적으로 확장시켜 사구의 모래 입자를 응집시켜 전사구의 모래를 유지하는데 기여한다(Lee et al., 2020). 통보리사초와 모래지치는 갯그렁 다음으로 만조선에 가까이 출현하는 식물 종으로 사구 식생 중 가장 높은 밀도를 보이는 종이다(Shin et al., 2015). 표 1은 각 식물에 대한 형태와 학명을 나타낸 표이다. 3종류의 사구 식생 모두 5월에 개화하며 갯그렁과 통보리사초는 서로 유사한 잎의 형태를 가지고 있다.

2. 무인항공기 기반 사구 식물 영상 촬영

본 연구에서는 환경영향평가 식물상 현장조사에서의 무인항공기 항공 촬영 방식을 적용하기 위해 상업용 무인항공기 제조업체 중 하나인 중국 DJI社의 Phantom4 RTK와 자체 짐벌 광학 센서를 사용하였다. 영상 촬영은 연구지역 11,738m²를 대상으로 2021년 8월 6일 고도 10m에서 실시되었으며, 영상 촬영 중복도는 횡·종 중복도 80%로 설정하였다(그림 2).

3. 딥러닝 기반 식생 분류 알고리즘

식생 군락의 분포 또는 종 분류 등과 관련된 연구에서 딥러닝을 활용한 연구가 활발히 수행되고 있다. 딥러닝이란 이미지, 음성, 텍스트 등의 정성적 정보를 입력값으로 받아 사람과 같이 인식하고 분류하는 심층신경망 기반의 알고리즘을 의미한다(He et al., 2016). 식생을 분류하는 방식은 크게 객체 인식(object detection)과 의미론적 분할(semantic segmentation)로 구분된다. 대부분의 선행 연구에서는 의미론적 분할이 아닌, 객체 인식이 주를 이루었는데, 이는, 의미론적 분할방식의 데이터 구축 비용이 다른 방식보다 크기 때문이다. 그러나 객체 인식은 개별 식생에 대한 분류를 목적으로 할 때, 식물의 크기, 구조, 분포가 매우 다양하기에, 부정확한 결과를 도출하는 단점이 존재한다(Zhang et al., 2020). 따라서 본 연구에서는 사구 식생의 형태와 분포를 파악하기 위해 의미론적 분할방식을 적용하였다.

본 연구에서는 U-net을 기반으로 학습을 수행하였다(그림 3). U-net은 대표적인 의미론적 분

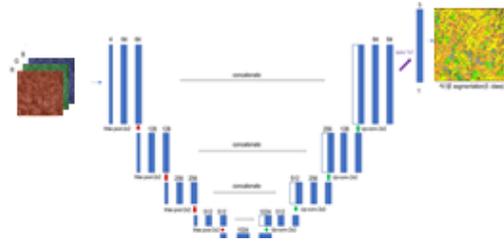


Figure 3. U-net 아키텍처 및 데이터 형태

할방식으로 분류 대상을 박스 형태가 아닌, 객체의 경계선을 따라 의미 있는 단위로 분류한다. U-net의 아키텍처는 입력 이미지를 처리하는 encoder 부분과 출력 이미지를 산출하는 decoder 부분으로 나뉜다. 이로 인해 encoder 부분에서의 특징을 spatial dimension 축소로 인한 손실 정보를 decoder 부분에서 skip-connection을 통해 점진적으로 복원시킬 수 있는 장점을 가지고 있다(Ronneberger et al., 2015).

신경망의 구조는 은닉층의 연결은 특징추출에 뛰어난 성능을 보이는 Relu활성화 함수를 적용하였으며, 출력층의 활성화 함수에는 분류하고자 하는 식생의 종류가 2개 이상으로 CE (Cross Entropy) Loss 적용 시에는 다중분류에 적합한 Softmax 함수를 적용하였으며, BCE (Binary Cross Entropy) Loss 적용 시에는 Sigmoid 함수로 출력을 처리하였다. 하나의 은닉층(Hidden layer)에는 300개의 노드가 존재하며 하나의 노드는 다음 은닉층의 모든 노드와 연결된 FC(Fully Connected) 방식을 적용하여 입력 데이터의 손실을 최소화하였다.

딥러닝 모델을 학습시킬 때에는 많은 양의 입력 데이터를 일괄적으로 처리하기 위해 고성능

Table 1. 대상종 학명 및 특징

국명	학명	특징	
갯그렁	<i>Leymus mollis</i> Trin	줄기 높이: 50~100cm 개화 시기: 5월	잎 길이: 20~40cm 잎 폭: 7~12mm
모래지치	<i>Messerschmidia Sibirica</i> L.	줄기 높이: 25~40cm 개화 시기: 5~6월	잎 길이: 4~10cm 잎 폭: 1~3cm
통보리사초	<i>Carex kobomugi</i> Ohwi	줄기 높이: 50~100cm 개화 시기: 4~5월	잎 길이: 20~30cm 잎 폭: 4~6mm

Table 2. HW/SW 및 학습 조건

HW	OS	Ubuntu 20.04.2 LTS
	CPU	Intel(R) Xeon(R) CPU E5-2630 v4
	Memory	DDR4 256GB
	GPU	NVIDIA TITAN Xp 12G
SW	개발언어	python 3.8.12
	프레임워크	CUDA 11.7 Pytorch 1.13
학습 조건	Epoch: 2000 batch size: 4 Learning rate: 0.0001 Loss Funtion: Cross Entropy & Binary Cross Entropy	

의 하드웨어가 요구된다. 이에 본 연구에서는 표 2과 같은 하드웨어 사양과 조건을 적용하여 학습과 검증을 수행하였다. 학습 속도에 영향을 가장 많이 주는 GPU는 머신러닝, 딥러닝 모델 학습에 최적화된 NVIDIA사의 TITAN Xp를 사용하였으며, 개발환경은 Python을 기반으로 만들어진 딥러닝 라이브러리인 Pytorch를 활용하여 구성하였다.

Epoch는 훈련 세트를 얼마나 반복해서 학습할지 결정하는 값이며, batch size는 한 번의 학습에 훈련 셋을 몇 개씩 입력할 것인지 결정하는 값이다. Learning rate는 반복적인 학습을 수행할 때 최솟값으로 수렴하게 되는 최적의 해를 찾아

가는 과정에서 다음 포인트를 얼마나 옮길지 결정하는 값이다. Loss Function은 모델이 학습을 수행할 때 요구되는 평가 지표로 어떠한 Loss를 적용하는지에 따라서 학습의 속도와 성능이 차이가 나타날 수 있다(Perez-Carabaza et al., 2021). 표 2에 나열된 학습 조건은 다양한 조건들을 조합하여 시뮬레이션에서 도출된 값이다.

U-net은 지도학습 알고리즘으로 촬영된 드론 영상과 함께 GT(Ground Truth)로 사용할 마스크 이미지가 요구된다. GT란 모델이 학습을 수행하며 내놓은 예측값이 얼마나 정확한지 비교할 수 있는 정답지이다. GT는 레이블링 작업을 통해 구축하였다.

4. 모델 고도화

분류 대상인 3종의 식생은 서로 뒤엉켜서 군락을 이루고 있는 지역이 많아 학습에 영향을 줄 가능성이 있다. 이에 Ignored label을 추가하여 모델을 고도화하였다. Ignored label이란 학습에서 제외되는 영역을 나타내는데, 주로 영상에서 분류하고자 하는 객체의 경계면을 따라 위치하며 해당 부분은 학습에서 제외하는 방식을 의미한다(그림 5). 이는 분류 대상의 경계면이 모호하거나 흐릿한 경우에 해당 부분에 대한 학습 수행이 부정확할 수 있는 문제를 해결하는 방안이다.

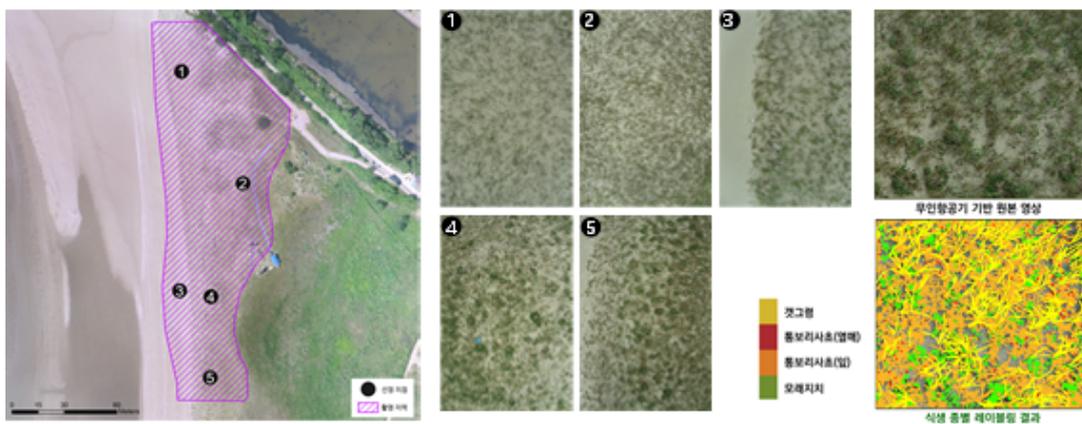


Figure 4. 신두리 해안사구 영상 취득 지점 및 GT 구축 예시

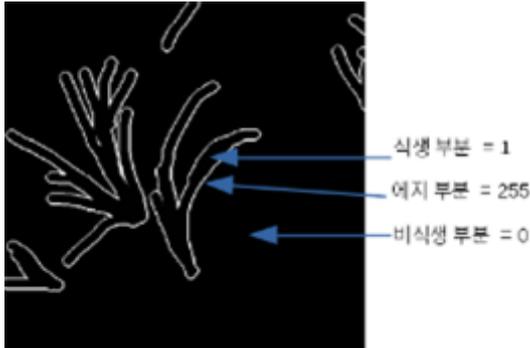


Figure 5. 갯그렁에 대한 Ignored label

III. 연구결과 및 고찰

1. 무인항공기 기반 학습/테스트 데이터 구축

연구대상지에서 무인항공기 기반 광학 센서 촬영을 통해 900장의 영상을 취득하였다. 촬영된 영상은 5472×3648 pixel 크기로, 그림 3에서 각 식생이 잘 발달한 지역과 혼합된 지형을 고려하여 임의로 5곳의 연구지역을 선정하였다(그림 4). 무인항공기로 촬영한 영상은 공간 해상도가 0.4cm급인 고해상도 자료로 식생의 잎과 열매 등 형태적 특성에 따라 분류할 수 있었다.

선정된 5곳의 영상에 대해서 각각을 4개의 클래스(갯그렁, 통보리사초(열매), 통보리사초(잎), 모래지치)로 구분하여 GT를 구축하였다. 각각의 영상을 512×512 사이즈로 약 3% 중복률을 주어 분할하였으며, GT 이미지는 학습 320장, 검증 72장, 테스트 48장으로 0.73:0.16:0.11 비율로 구성하였다. GT 구축에 소요된 시간은 약 240시간이다.

영상에서 갯그렁과 통보리사초는 잎의 형태

가 비슷하기에 두 식물을 구분하기 위해서는 통보리사초의 열매를 가지고 구분할 수 있었다. 이를 모델에 반영하기 위해 통보리사초의 클래스를 열매와 잎으로 구분하였다.

2. 딥러닝 모델 학습 결과

U-net과 같은 segmentation 모델의 성능 평가는 모델이 산출한 Prediction map과 GT를 중첩하여 얻어진 몇 가지 지표를 통해 수행한다. 본 연구에서는 mIoU(mean Intersection over Union)를 통해 모델의 성능을 평가하였다. mIoU는 구분 대상의 예측 영역과 실제 영역의 합집합 넓이에 대한 교집합의 넓이를 비율로 나타내어 모든 사진의 평균을 산출한 값이다. mIoU의 정의역은 0에서 1사이로 1에 가까울수록 높은 정확도를 의미한다.

레이블링 영상들이 여러 층(Layer)으로 구성되고 서로 중첩되는 영역이 발생하기 때문에 이를 고려한 Loss Function 선정이 필요하다. CE Loss는 의미론적 분할방식에서 가장 자주 사용하는 손실함수이다. 다만, 분류하고자 하는 클래스의 개수만큼 개별적으로 모델을 구성하고 각각 학습을 수행해야 하는 단점이 있다. 반면, BCE Loss는 여러 층의 레이블을 동시에 학습할 수 있어, 결과 또한 정해진 클래스의 수만큼 산출되는 특징이 있다.

표 3은 Ignored Label 적용 여부와 CE Loss와 BCE Loss 적용에 따른 모델의 성능을 클래스별 mIoU로 판단한 결과이며, 그림 6은 클래스별 테스트 이미지에 관한 결과를 식생별로 나열한 것이다. 모든 클래스에서 Ignored Label이 적용

Table 3. Ignored label 적용 여부 및 손실함수에 따른 클래스별 mIoU 결과

Class	Ignored label 미적용	Ignored label 적용	Ignored label 적용
	BCE Loss	BCE Loss	CE Loss
갯그렁	0.6082	0.6739	0.7218
통보리사초 열매	0.5478	0.5961	0.6680
통보리사초 잎	0.6418	0.6965	0.7216
모래지치	0.6635	0.7178	0.7551

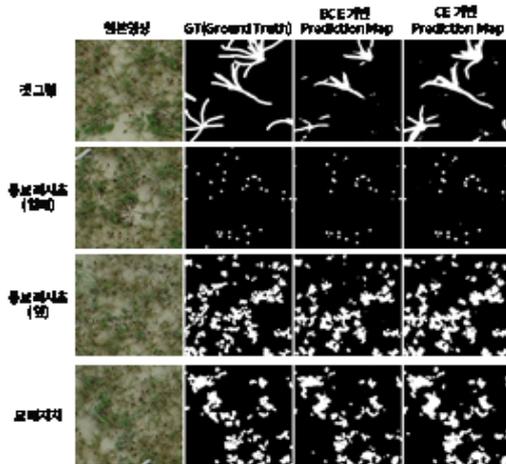


Figure 6. 클래스별 테스트 결과 이미지

된 CE Loss의 성능이 높게 나타났으나, CE Loss는 6개의 모델을 독립적으로 학습을 수행시키는 문제로 인해 시간적인 효율성이 낮다. 즉, 클래스의 수가 많아질수록 CE Loss를 적용하는데 한계가 존재하기에 효율성 측면에서 BCE Loss가 더 우수하다고 판단할 수 있다.

그러나 mIoU의 값을 더 높일 수 있는 여지가 남아있어 Data Argumentation 기법을 활용하여 추가적인 촬영 없이 데이터셋 증강에 대한 방안을 모색하는 것도 고려할 필요가 있다. 대표적으로 Bootstrap은 기존의 데이터 셋으로부터 랜덤 샘플링을 통해 학습데이터를 늘리는 방안으로 데이터의 절대적 양을 증가시킬 수 있을뿐더러 분포를 고르게 만들 수 있는 효과가 있다. 또한, 5장의 원본 영상에 대해서 GT 구축을 하는데 약 10일 정도 소요되는 점을 고려했을 때, 전문 GT 구축 업체를 통한 레이블링이 필요할 것으로 판단된다.

모델 고도화 측면에서는 온라인상에 올라와 있는 검증된 사구 식생의 이미지를 수집하여 사전 학습을 수행하고 대상지에 대한 사구 식생을 학습하는 방식의 전이학습 방식을 고려할 필요가 있다. 또는 U-net 외에 HR-net, DeepLap v3+ 등의 다른 딥러닝 모델을 개발하여 각 모델의 성능을 비교하는 방안도 향후 연구로 진행될 필요

가 있을 것으로 판단된다. 또한, 모델 학습에 사용된 이미지는 특정 시기에만 수집된 자료로 취득 영상의 다양성이 아직 충분하지 못한 상태로 실제 필드에서의 성능은 다를 수 있으며, 이를 위한 다양한 시기의 이미지 취득이 요구된다.

IV. 결 론

본 연구는 신두리 해안사구의 관리를 위해 무인항공기로 취득한 고해상도 영상과 딥러닝 알고리즘을 활용하는 모니터링 방식을 제안하였다. 클래스의 분류는 U-net을 활용하여 박스 형태가 아닌, 객체의 경계를 따라 분류하는 방식인 의미론적 분할방식을 적용하였다. 클래스는 갯그렁, 통보리사초 열매, 통보리사초 잎, 모래지치로 분류하였으며 총 320장의 학습 이미지와 48장의 테스트 이미지로 모델의 학습과 테스트를 수행하였다. 모델의 성능향상을 위해 Ignored label을 적용하는 방식과 더불어 CE Loss, BCE Loss 2가지 방식의 손실함수를 적용하여 모델의 성능을 평가하였다. 평가 결과, CE Loss를 적용했을 때, 클래스별 mIoU의 값이 가장 크게 나타났으나, 학습에 소모된 시간적 효율성을 고려했을 때 BCE의 성능이 더 우수하다고 판단할 수 있다.

환경영향평가, 자연환경 조사 등 기존의 식생 모니터링을 위해서는 조사자가 직접 현장에서 정해진 경로에 대해서만 조사를 수행하며, 중동정에도 다소 오랜시간이 소요될 수 있다. 반면, 무인항공기와 딥러닝 모델을 활용하면 시간과 인력대비 효율성을 높일 수 있으며 특정종의 분포 파악이 가능하고 분포 면적을 정량적으로 산출할 수 있는 장점이 있다.

본 연구에서는 사구 식생이 분포한 일부 지역과 단일한 시간대에 얻어진 영상만을 가지고 알고리즘을 구축하였다. 때문에, 다른 지역의 사구 식생과 다양한 계절에 촬영된 영상에 대한 분류에는 한계가 존재한다. 다만, 사구 식생을 모니터링하고 관리하는 방안으로 무인항공기와 딥

러닝을 시범적으로 적용한 하나의 사례로서 의의가 있다. 본 연구를 통해 딥러닝 영상 분석 기술의 사구 식생 모니터링 활용 가능성을 확인할 수 있었으며, 향후 사구 식생뿐만 아니라 하천, 산림, 초지 등의 다양한 현장에서도 제안하는 방식을 활용할 수 있을 것으로 기대한다.

References

- De Giglio, M., Greggio, N., Goffo, F., Merloni, N., Dubbini, M., & Barbarella, M. (2019). Comparison of pixel-and object-based classification methods of unmanned aerial vehicle data applied to coastal dune vegetation communities: Casal borsetti case study. *Remote Sensing*, 11(12), 1416.
- Ettritch, G., Bunting, P., Jones, G., & Hardy, A. (2018). Monitoring the coastal zone using earth observation: application of linear spectral unmixing to coastal dune systems in Wales. *Remote Sensing in Ecology and Conservation*, 4(4), 303-319.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Kahng, T. (2006). The landforms and vegetation of coastal sanddune natural monument at Sindu-ri, Taegun, South Chungcheong Province. *Journal of the Korean Geomorphological Association*, 13(3), 35-44.
- Kim, D. W., Lee, S. H., Yu, J. J., & Son, S. W. (2021). Image analysis technology with deep learning for monitoring the tidal flat ecosystem-Focused on monitoring the *Ocypode stimpsoni* Ortmann, 1897 in the Sindu-ri tidal flat. *Journal of the Korean Society of Environmental Restoration Technology*, 24(6), 89-96.
- Laporte-Fauret, Q., Lubac, B., Castelle, B., Michalet, R., Marieu, V., Bombrun, L., ... & Rosebery, D. (2020). Classification of atlantic coastal sand dune vegetation using in situ, UAV, and airborne hyperspectral data. *Remote Sensing*, 12(14), 2222.
- Lee, J. Y., Cheong, J. H., & Kim, H. S., (2020). A Study Monitoring the Changes in Taean Sindu Coastal Sand Dune Vegetation. *The Journal of Korean Island*, 32(3), 187-202.
- Perez-Carabaza, S., Boydell, O., & O'Connell, J. (2021, July). Monitoring Threatened Irish Habitats Using Multi-Temporal Multi-Spectral Aerial Imagery and Convolutional Neural Networks. In *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS* (pp. 2556-2559). IEEE.
- 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.
- Shin, H. S., Kim, T. G., & Yun, C. W. (2015). Phytosociological vegetation classification and flora for the mid-west coast in Korea. *Korean Journal of Apiculture*.
- Soltani, S., Feilhauer, H., Duker, R., & Kattenborn, T. (2022). Transfer learning from citizen science photographs enables plant species identification in UAVs imagery. *ISPRS Open Journal of Photogrammetry and Remote Sensing*, 100016.
- Song, H. S., & Cho, W. (2007). Diversity and zonation of vegetation related micro-topography in Sinduri coastal dune, Korea-focused on the

- natural monument area. *Korean Journal of Environment and Ecology*, 21(3), 290-298.
- Song, H., Park, G., Park, H., Seo, E., So, S., & Kim, M. (2005). Vegetation and Soil Properties of the Coastal Sand Dune in Sinduri, Taean Gun. *Journal of the Korean Society of Environmental Restoration Technology*, 8(6), 59-68.
- Villoslada, M., Bergamo, T. F., Ward, R. D., Burnside, N. G., Joyce, C. B., Bunce, R. G. H., & Sepp, K. (2020). Fine scale plant community assessment in coastal meadows using UAV based multispectral data. *Ecological Indicators*, 111, 105979.
- Zhang, C., Atkinson, P. M., George, C., Wen, Z., Diazgranados, M., & Gerard, F. (2020). Identifying and mapping individual plants in a highly diverse high-elevation ecosystem using UAV imagery and deep learning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 169, 280-291.