

# UAV 다중분광 영상 기반 딥러닝 토석채취지 분류를 위한 최적 데이터세트 구성 및 평가

박동환<sup>1</sup>·심우담<sup>2\*</sup>

## Dataset Construction and Evaluation for Deep Learning-based Quarry Classification Using UAV Multispectral Images

Dong-Hwan Park<sup>1</sup>·Woo-Dam Sim<sup>2\*</sup>

### 요 약

본 연구는 토석채취지 모니터링의 자동화 및 효율화를 위한 딥러닝 기반 분류 모델의 최적 데이터세트를 선정하고자 하였다. 연구대상지는 경상북도 구미시에 소재한 면적 약 8.5ha 규모의 토석채취 사업장으로, DJI M3M 무인항공기를 활용하여 RGB 및 멀티스펙트럴 영상을 취득하였다. 취득된 영상을 기반으로 분광정보 구성, 방사해상도를 고려하여 네 가지 데이터세트를 구성하였다. 토석채취지의 분류 모델로는 고해상도 특징 유지에 강점이 있는 HRNetV2를 선정하였으며, MS-SSIM, Focal Loss, Dice Loss를 결합한 Hybrid Loss를 활용하여 모델을 학습하였다. 연구 결과, Dataset C가 전체 정확도 92.8%, Kappa 계수 0.875로 가장 균형 잡힌 분류 성능을 보였다. 특히 다른 데이터세트에서 낮은 정확도를 보인 초지(81.0%)와 습지(87.4%) 분류에서도 우수한 성능을 나타냈다. 반면, DSM과 Slope 정보를 추가한 Dataset D는 과적합 문제가 발생하여 모델의 일반화 능력이 저하되었다. 주요 오분류는 급격한 지형변화 지역의 산림지↔초지 간 혼동과 토지피복 경계부의 초지→나지 오분류로 나타났다. 본 연구는 분광정보 구성, 방사해상도에 따른 차이, 지형정보의 추가활용 등 데이터세트 구성에 따른 토석채취지 분류 정확도 향상 여부를 검토하였으며, 이러한 최적 데이터세트 구성에 대한 연구결과는 향후 토석채취지 자동 분류 시스템 개발을 위한 기초자료로 활용될 수 있을 것으로 판단된다.

주요어 : 무인항공기, 딥러닝, 모니터링, HRNetV2, 다중분광

2024년 11월 25일 접수 Received on November 25, 2024 / 2024년 12월 11일 수정 Revised on December 11, 2024 / 2024년 12월 19일 심사완료 Accepted on December 19, 2024

1 한국산지보전협회, 연구원 / Korea Forest Conservation Association, Daejeon, Republic of Korea, Researcher

2 강원대학교 산림경영학과, 박사후연구원 / Department of Forest Management, Division of Forest Sciences, College of Forest and Environmental Sciences, Kangwon National University, Postdoctoral Researcher

\* Corresponding Author E-mail: swdawd@naver.com

## ABSTRACT

This study aimed to determine the optimal dataset for a deep learning-based classification model to automate and enhance the efficiency of quarry monitoring. The study site was a quarry with an area of approximately 8.5ha, located in Gumi, Gyeongsangbuk-do, where RGB and multispectral images were acquired using a DJI M3M drone. Four datasets were constructed based on the acquired images, considering spectral information composition and radiometric resolution. HRNetV2, which excels in maintaining high-resolution features, was selected as the classification model for the quarry, and the model was trained using a Hybrid Loss combining MS-SSIM, Focal Loss, and Dice Loss. The results showed that Dataset C demonstrated the most balanced classification performance with an overall accuracy of 92.8% and a Kappa coefficient of 0.875. Notably, it showed excellent performance in classifying grassland (81.0%) and wetland (87.4%), which had lower accuracy in other datasets. In contrast, Dataset D, which included DSM and Slope information, experienced overfitting problems, resulting in reduced model generalization capability. The main misclassifications occurred in the confusion between forest and grassland in areas with steep terrain changes, and grassland being misclassified as bare land in land cover boundary areas. This study examined the improvement in quarry classification accuracy according to dataset composition, including differences in spectral information configuration, radiometric resolution, and the additional use of topographic information. These findings on optimal dataset configuration are expected to serve as foundational data for the future development of automated quarry classification systems.

*KEYWORDS : UAV, Deep Learning, Monitoring, HRNetV2, Multi-Spectral*

## 서론

산림은 토지에서 가장 중요한 생태자원이며, 탄소 균형, 생물다양성, 에너지 순환 등에서 핵심적인 역할을 수행하는 생태계의 근간이다(Navar, 2015). FAO(Food and Agriculture Organization) 보고서에 따르면 전 세계 토지피복의 약 1/3이 산림으로 구성되어 있으며, 특히 기후변화 완화를 위한 중요한 탄소 흡수원으로서의 가치를 인정받고 있다(FAO, 2010). 우리나라는 국토의 약 70%가 산림으로 구성되어 있으나, 불법산지전용, 농경지 개간, 산사태 등 인위적 훼손 및 재해발생으로 인한 산림 훼손이 지속적으로 발생하고 있다(Park et al., 2016).

특히, 토석채취는 채굴과정에서 산지를 직접적으로 훼손할 뿐만 아니라, 흙, 먼지, 토사유출

등 2차적 환경 피해를 유발하는 주요 원인이 되고 있다. 이러한 문제에 대응하기 위해 현재는 계단식 채석방식이 도입되었으며, 채굴활동이 종료된 지역에 대해서는 묘목, 초본류 등을 통한 복구작업이 진행되고 있다. 그러나 우리나라의 토석채취지는 소규모 사업장이 많아 사업 중단이나 미흡한 복구로 인한 자연경관 훼손 및 사회적 문제가 빈번히 발생하고 있다(Park et al., 2010). 이와 같이 토석채취는 자연경관 훼손과 다양한 환경피해를 수반하기 때문에 토석채취지의 복구 실태 분석, 인위적 훼손비탈면 복구지의 실태 조사 등 다양한 연구가 진행되고 있다(Park, 2012). 현재 산림청은 매년 전국 약 500개소의 토석채취 허가를 대상으로 무인항공기(Unmanned Aerial Vehicle, UAV) 기반 모니터링을 실시하고 있다. 이를 통해 정사영상 및 Digital Surface Model (DSM)을 구

측하고, 사업장의 경계침범 여부, 계단식 채석여부, 배수로 및 침사지 관리 여부 등을 점검하고 있다. 하지만 현행 모니터링 방식은 많은 시간과 비용이 소요되는 한계가 있어 보다 효율적인 자동화 기법의 도입이 요구되고 있다.

원격탐사 분야에서는 전통적으로 픽셀기반 및 객체기반 분류방법이 활용되어 왔다(Im et al., 2009; Choung, 2014; Gärtner et al., 2014; Won et al., 2014; Kwon et al., 2021). 픽셀기반 분류방법은 영상의 화소값을 분석하여 분류하는 기법으로, 동일한 범주 내에서 화소값의 변동이 발생할 경우 분류정확도가 낮아지는 한계가 있다. 객체기반 분류방법은 기하학적·공간적으로 동일한 속성을 갖는 인접한 화소를 객체로 구분하여 분류하는 기법으로, 기존 픽셀기반 분류방법의 한계를 보완하기 위해 도입되었다(Liu and Xia, 2010; Schöpfer et al., 2010). 그러나 Basu et al.(2015)은 객체기반 분류방법에서도 분류의 한계점이 존재하며, 정확도 높고 빠른 갱신주기를 가지는 토지피복도 구축을 위해서는 보다 고도화된 방법이 필요하다고 제안하였다. 최근에는 이러한 한계를 극복하기 위해 기계학습, 딥러닝과 같은 인공지능 기술을 적용한 연구가 활발히 진행되고 있다. 특히 LeCun et al.(1989)이 제안한 합성곱 신경망(Convolutional Neural Network, CNN)기반 영상분류기법은 기존의 전통적인 분류방법과 달리 영상의 특징을 자동으로 학습하고 추출할 수 있어, 복잡한 공간패턴 인식에 뛰어난 성능을 보인다. 토석채취지와 같이 다양한 토지피복이 혼재되어 있고 계단식 채석으로 인한 복잡한 지형특성을 가진 지역의 경우, 기존의 픽셀 또는 객체 단위의 분류방법으로는 정확한 구분이 어려울 수 있다. 반면 딥러닝 기반의 분류는 패치(patch) 단위로 학습이 이루어져 주변의 공간적 문맥정보를 함께 고려할 수 있으며, 합성곱 연산을 통해 국소적 영역의 특징을 추출하고, 계층적 구조를 통해 다양한 수준의 특징을 동시에 학습할 수 있다는 장점이 있다(Garcia-Garcia et al., 2017). 특히 의미론적 분할(Semantic Segmentation) 모델의 경우,

영상 내 각 픽셀의 클래스를 예측하면서도 전체적인 공간 맥락을 보존할 수 있어 토석채취지의 복잡한 공간패턴을 효과적으로 분류할 수 있다.

한편, 원격탐사 기반의 토지피복 분류에서는 가시광선 영역의 RGB 영상과 함께 Near Infrared (NIR) 및 Red-Edge 파장대역을 포함하는 멀티스펙트럴 영상이 널리 활용되고 있다. 이는 식생이 근적외선 영역에서 높은 반사율을 보이는 반면, 토양이나 암반은 상대적으로 낮은 반사율을 나타내는 분광특성을 활용할 수 있기 때문이다. 특히 적외선 경계 밴드는 식생의 엽록소 함량과 밀접한 관련이 있어, 식생과 비식생 지역의 구분에 효과적이다(Rouse et al., 1974; Delegido et al., 2011). 이러한 분광특성은 토석채취지와 같이 식생이 훼손된 지역의 탐지에 있어 중요한 정보를 제공할 수 있다.

이러한 배경에서 본 연구는 토석채취지의 효과적인 자동 분류를 위한 최적의 데이터세트 구성에 주목하였다. 토석채취지는 산림, 초지, 나지 등 다양한 토지피복이 혼재되어 있으며, 계단식 채석으로 인한 복잡한 지형 특성을 보인다. 이러한 토석채취지의 특성을 고려할 때, 분류 정확도 향상을 위해서는 딥러닝 모델의 구조뿐만 아니라 입력 데이터의 특성이 중요한 요소가 될 수 있다. 특히 딥러닝 모델의 특징 학습 능력을 최대한 활용하기 위해서는 RGB 영상, 근적외선 정보, 방사해상도의 차이, 지형정보 등 다양한 입력 데이터의 조합이 모델의 성능에 미치는 영향을 체계적으로 분석할 필요가 있다. 따라서 본 연구는 고해상도 무인항공기 영상의 가시광선 및 멀티스펙트럴 데이터를 활용하여 다양한 데이터세트를 구성하고, 이들의 분류 정확도를 비교·분석하여 토석채취지 분류에 최적화된 데이터세트를 선정하고자 한다. 본 연구를 통해 토석채취지 모니터링의 자동화 및 효율화에 기여할 수 있을 것으로 기대되며, 나아가 산림 보전 및 관리를 위한 의사결정 지원에도 도움이 될 것으로 전망된다.

## 연구방법

### 1. 연구대상지 및 사용자료

본 연구의 대상지는 경상북도 구미시에 소재한 면적 약 8.5ha 규모의 토석채취 사업장이다. 연구대상지의 지형현황은 북에서 남으로 갈수록 고도가 점진적으로 상승하는 특성을 보인다. 북측 진입로는 해발고도 120m에 위치하며, 사업장 내부는 140~150m로 분포한다. 남쪽 채취구역은 계단식 구조로 구성되어 있으며, 해발고도 175m에서 시작하여 최고점 300m까지 단계적으로 고도가 증가한다. 특히, 사업장 내부 최저지점(150m)과 계단식 채취구역 최상단부(300m)사이에는 약 150m의 큰 고도 차이가 존재하여, 전형적인 토석채취지의 지형적 특성을 나타낸다(그림 1).

연구대상지의 영상 취득은 DJI社의 M3M 무

인항공기(Unmanned Aerial Vehicle, UAV)를 활용하였다. 해당 기종은 8비트 RGB 카메라와 16비트의 다중분광(Multi-Spectral, MS) 카메라를 탑재하고 있어 Green, Red, Red-Edge, Near-Infrared (NIR) 파장대역의 촬영이 가능하다. 영상 촬영은 2024년 9월 5일에 실시하였으며, 비행고도 150m, 영상 중첩도 90% 조건 하에서 RGB 이미지 340매와 다중분광 이미지 318매를 취득하였다. 영상의 위치 정확도 향상을 위해 Global Navigation Satellite System (GNSS) 기준국을 설치하고 후처리 이동측위(Post-Processing Kinematic, PPK) 보정을 수행하였다. 후처리 이동측위 방식은 기지국과 드론 사이에 실시간 연결이 필요 없으므로 통신 신호에 영향을 받지 않아 원활한 작업이 가능하다는 이점이 있다(Park and Kim, 2021).




FIGURE 1. Study area

## 2. 연구방법

촬영한 UAV 영상을 기반으로 정사영상 및 Digital Surface Model (DSM)을 제작하였으며, 토석채취지의 의미론적 분할을 위한 입력자료로 활용하였다. 딥러닝 모델은 딥러닝 모델은 HRNetV2를 활용하였으며 모델 간의 비교, 아키텍처의 구성보다는 데이터세트 구성에 따른 분류 정확도를 항상 여부를 중점으로 검토하였으며, 분광정보 구성, 방사해상도, 지형정보의 추가활용을 고려하여 Dataset A(8bit Red, Green, Blue), Dataset B(8bit Red, Green, Red-Edge, NIR), Dataset C(16bit Red, Green, Red-Edge, NIR), Dataset D(16bit Red, Green, Red-Edge, NIR, DSM, Slope) 등 4가지 데이터세트를 구성하였다. 구축한 데이터세트는 딥러닝 모델을 활용하여 학습 및 검증 과정을 수행 후, 딥러닝 기반 분류지도를 구축하였으며, 라벨 이미지와의 정확도 비교·검토를 통해 최적의 데이터세트를 선정하였다.





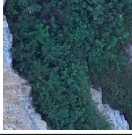



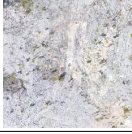

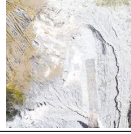

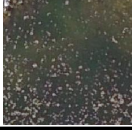

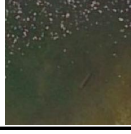

- 1) UAV 정사영상 및 지형정보 구축  
영상처리는 Agisoft社의 Metashape 소프트웨어

웨어를 활용하여 정사영상 및 DSM을 제작하였다. 취득된 영상의 메타데이터로부터 촬영좌표, 고도, 카메라 각도 등의 정보를 추출하여 공간좌표계에 따라 이미지를 정렬하였다. 정렬된 이미지는 국토지리정보원의 KN-Geoid18 지오이드 모델을 적용하여 고도값을 보정하고, 렌즈 왜곡 보정을 수행하였다. 이후 보정된 이미지로부터 특징점을 추출하여 Point Cloud를 생성하고, 공간보간법을 통해 Point Cloud 사이의 공백을 보완하여 3D Mesh를 제작하였다. 이후 3D Mesh의 고도값을 Raster 형태의 DSM으로 변환하고, 촬영 이미지의 텍스처 정보를 3D Mesh와 중첩하여 정사영상을 구축하였다. 정사영상과 DSM은 공간해상도 5cm인 고해상도 Raster 정보로 구축하였으며, 지형정보인 Slope는 지리공간 프로그램인 QGIS를 통해 DSM을 기반으로 제작하였다.

### 2) 딥러닝 모델의 데이터세트 구축

딥러닝 모델의 데이터세트는 학습자료, 검증자료, 테스트자료로 구성된다. 학습 및 검증자료는 모델 학습과정에 활용되며, 테스트자료는 학

TABLE 1. Criteria by label data categories

Category	Definition	Example			
Forest	Forested regions characterized by the presence of multiple ( $\geq 2$ ) arboreal specimens within the vegetative cover stratum				
Grassland	Regions characterized by herbaceous vegetation and shrub communities				
Bare Land	Level terrain composed of soil, asphalt, and rock formations				
Wetland	Aquatic zones characterized by flowing or stagnant water bodies				

습된 모델의 분류지도 제작에 활용된다. 의미론적 분할(Semantic Segmentation) 기반 딥러닝 모델에서 학습 및 검증자료는 입력 이미지와 라벨 이미지로 구성되며, 테스트자료는 입력 이미지만으로 구성된다. 입력 이미지는 영상의 분광 정보가 포함된 원본 이미지이며, 라벨 이미지는 분류 범주가 기입된 참값 자료를 의미한다. 입력 이미지와 라벨 이미지는 래스터 형태로 구성되어야 하며, 딥러닝 모델의 구조에 따라 타일 형식으로 분할되어야 한다.

토석채취지 탐지 정확도 향상을 위해 입력 이미지의 분광정보 구성을 다르게 한 4가지 데이터셋을 구축하였다: Dataset A(8bit RGB), Dataset B(8bit Red, Green, Red-Edge, NIR), Dataset C(16bit Red, Green, Red-Edge, NIR), Dataset D(16bit Red, Green, Red-Edge, NIR, DSM, Slope). 이러한 구성은 영상의 방사해상도, 근적외선 활용, 지형정보 활용에 따른 분류정확도 변화를 비교하기 위해 설계되었다. 라벨 이미지는 정사영상의 육안판독을 통해 구축하였으며, 분류범주는 산림지, 초지, 나지, 습지의 4개 항목으로 구성하였다(표 1). 토석채취지 모니터링에서는 채석작업 이후 계단식 채석지역의 관목, 초본류 등을 통한 적절한 복구 여부가 중요하므로 식생영역을 산림지와 초지로 구분하였다. 또한 토석채취지 내부의 침사지, 배수로 등 배수시설 설치 현황 파악이 중요한 모니터링 요소이므로 습지를 별도 항목으로 구분하였다. 일반적인 토석채취 지역, 작업로, 토양은 분광분포가 유사하기 때문에 나지로 통합 분류하였다.

데이터셋 구축을 위한 타일 이미지의 크기는  $256 \times 256$  pixel ( $12.8\text{m} \times 12.8\text{m}$ )로 설정하였다. 연구대상지에서 생성된 총 1,148개 타일 중 랜덤샘플링 기법을 통해 전체 타일의 약 30%인 344개를 선정하여 학습자료로 활용하였으며, 학습자료로 활용되지 않은 자료 중 전체 타일의 20%인 229개를 검증자료로 선정하였다. 테스트자료는 딥러닝 모델에서 흔히 발생하는 이미지 외곽 부분의 낮은 분류 정확도 문제를 해결하기 위해 연구대상지 전체 영역을 대상


으로 이미지 중첩율 50%를 적용하여 총 4,731개의 타일을 생성하였으며, 최종 분류 이미지 제작 시에는 중복을 방지하기 위해 각 타일의 중심부 50% 영역만을 활용하였다.

### 3) 토석채취지 탐지를 위한 딥러닝 모델 선정

토석채취지는 토양, 초본류, 습지, 산림지, 인공구조물 등 다양한 피복이 분포하고 있으며, 각각의 객체들이 서로 다른 형태와 크기로 존재한다. 이러한 복잡한 특성을 고려할 때, 높은 해상도의 특징정보를 유지하면서 정확한 분할이 가능한 딥러닝 모델이 필요하다. 본 연구는 토석채취지 탐지를 위해 HRNetV2 모델을 활용하였다. HRNetV2는 기존의 합성곱 신경망(Convolutional Neural Network, CNN) 기반 모델들과 달리, 다중 해상도 특징을 동시에 유지하며 처리할 수 있어 큰 구조의 객체와 세밀한 경계를 동시에 포착할 수 있는 장점이 있다. 또한, Multi-scale Fusion Module을 통해 효과적인 특징 융합으로 복잡한 지형 패턴을 더 잘 인식할 수 있다는 장점이 있어 토석채취지 탐지를 위한 딥러닝 모델로 적합하다고 판단하였다.

초기 모델인 HRNet은 2019년 Horizon Robotics社에서 개발한 CNN 기반 딥러닝 알고리즘이다. 기존 의미론적 분할 기법의 모델들은 인코더(Encoder)-디코더(Decoder) 구조로 구성되어 있어, 인코더에서 합성곱 층(Convolution Layer)을 통해 상세 특징량을 추출하는 과정에서 해상도가 점차 감소하게 된다. 디코더는 감소한 해상도를 복구하는 단계이나, 이 과정에서 정보의 손실이 발생하는 한계가 있다. HRNet은 이러한 단점을 해결하기 위해 입력 영상을 다양한 해상도에서 처리하여 정보의 손실을 최소화하고, 높은 해상도의 정보를 유지하도록 설계되었다(Sun et al., 2019).

HRNetV2는 2020년에 발표된 개선 모델로, 기존 HRNet의 장점을 유지하면서 Multi-scale Fusion Module을 도입하여 특징 표현과 융합 능력을 향상시켰다. 이 모듈은 서로 다른 해상도의 특징맵 간 양방향 정보 교환을 가능하게 하여 각 해상도 수준에서 풍부한 문맥 정보를 포착할



Reference : Wang et al., 2019, Deep High-Resolution Representation Learning for Visual Recognition

FIGURE 2. HRNetV2 architecture

수 있다. HRNetV2의 네트워크는 Stem Network와 4개의 High-Resolution Stages로 구성된다(그림 2). Stem Network는 입력 이미지를 초기 처리하는 단계로, 스트라이드와 컨볼루션 층을 통해 특징맵의 해상도를 1/4로 축소한다. High-Resolution Stages는 단계별로 1개에서 4개까지의 병렬 브랜치를 운영하며, 각각 다른 해상도의 특징을 처리한다. Multi-scale Fusion Module은 교차 해상도 융합을 주요 특징으로 한다. 상향 융합 시에는 보간법과 1x1 컨볼루션을 조합하여 정보 손실을 최소화하고, 하향 융합 시에는 스트라이드 컨볼루션을 통해 효율적인 다운샘플링을 수행한다. 또한 적응형 융합 가중치 메커니즘과 잔차 연결을 도입하여 학습 안정성을 향상시켰다. Task-specific Head Network도 개선되어 Segmentation Head에서는 향상된 특징 집계 방식을, Classification Head에서는 개선된 특징 표현 방식을 적용하였다(Cheng et al., 2020; Wang et al., 2020; Li

et al., 2023). 이러한 개선을 통해 HRNetV2는 향상된 특징 표현력, 정확도, 계산 효율성, 그리고 확장성을 제공한다.

#### 4) 딥러닝 모델 기반 분류지도 구축 및 정확도 평가

딥러닝 모델의 학습은 AMD Ryzen 9 5950X CPU(16core 3.4GHz), 128GB RAM, NVIDIA RTX3090 GPU 환경에서 수행되었다. 모든 모델의 학습횟수(Epoch)는 100회로 설정하였으며, 선행연구를 참조하여 AdamW Optimizer와 OneCycleLR 기법을 통해 학습율을 유동적으로 조정하였다(Loshchilov and Hutter, 2017; Smith and Topin, 2019). 손실함수는 데이터셋의 범주별 불균형 문제와 과적합 방지를 위해 세 가지 손실함수를 결합한 Hybrid Loss를 활용하였다(식 1). Hybrid Loss는 MS-SSIM (Multi-Scale Structural SIMilarity), Focal Loss, Dice Loss로 구성된다. MS-SSIM은 이

$$L^{Hybrid} = \frac{L^{MS-SSIM} + L^{Focal} + L^{Dice}}{3} \quad (1)$$

$$L^{MS-SSIM} = \prod_{i=1}^M c_m \times l_m \times s_m \quad (2)$$

$$L^{Focal} = - \sum_{i=1}^C \alpha_i (1 - p_i)^\gamma y_i \log(p_i) \quad (3)$$

$$L^{Dice} = 1 - \frac{1}{C} \sum_{i=1}^C \frac{2 \sum_j p_{ij} y_{ij} + \epsilon}{\sum_j p_{ij} + \sum_j y_{ij} + \epsilon} \quad (4)$$

$\epsilon$  : 상수항,  $M$  : 스케일의 수,  $c_m$  : m번째 스케일의 대비 지수,  $l_m$  : m번째 스케일의 밝기 지수,

$s_m$  : m번째 스케일의 구조 지수,  $C$  : 범주 수,  $\alpha_i$  : i번째 범주의 가중치,  $p_i$  : i번째 범주에 대한 모델의 예측 확률,  $\gamma$

: 손실 패널티 조절 매개변수,  $y_i$  : i번째 범주에 대한 One-Hot Encoding 라벨,

$p_{ij}$  : j번째 픽셀에 대한 i번째 범주의 예측 확률,  $y_{ij}$  : j번째 픽셀에 대한 i번째 범주의 One-Hot Encoding 라벨,

$$\text{Overall Accuracy} = \frac{TP + TN}{TP + FP + TN + FN} \quad (5)$$

$$\text{kappa} = \frac{OA - p_e}{1 - p_e} \quad (6)$$

$$p_e = \left( \frac{TP + FN}{TP + FN + FP + TN} \times \frac{TP + FP}{TP + FN + FP + TN} \right) + \left( \frac{FP + TN}{TP + FN + FP + TN} \times \frac{FN + TN}{TP + FN + FP + TN} \right) \quad (7)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (8)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (9)$$

$$F_1 - \text{Score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (10)$$

미지의 대비, 밝기, 구조 차이를 다양한 스케일에서 종합적으로 계산한다(식 2)(Wang et al., 2003). Focal Loss는 데이터 불균형 문제 해결을 위해 개발되었으며,  $i$ 번째 범주의 가중치( $\alpha$ )와 분류 정확도가 높은 이미지의 손실 패널티를 조절하는 매개변수( $\gamma$ )를 활용하여 분류정확도가 낮은 이미지에 더 큰 가중치를 부여한다(식 3)(Lin et al., 2017). Dice Loss는 각 범주에 대한 Dice Coefficient의 평균값으로 계산되며, 예측값과 라벨 이미지 간의 중복영역이 클수록 0에 가까운 0-1 범위의 값을 가진다. Dice Loss는 Focal Loss와 마찬가지로 범주별 불균형 데이터에 효과적인 것으로 알려져 있다(식 4)(Milletari et al., 2016).

분류 정확도 평가는 학습된 모델을 테스트 자료에 적용하여 생성된 분류지도와 라벨 이미지를 비교하여 수행하였다. 정확도 평가를 위해 혼동행렬(Confusion Matrix)을 작성하고 Overall Accuracy와 Kappa 계수를 산출하여 모델의 전반적인 분류 성능을 정량적으로 평가하였다(식 5-7)(Rouhi et al., 2015; Huang and Rust, 2018). 범주별 분류 정확도는 Precision과 Recall을 기반으로 한 F1-Score를 통해 평가하였다(식 8-10).

## 연구 결과

### 1. 데이터셋의 범주별 분광분포

딥러닝 데이터셋의 라벨이미지 구축 결과,

범주별 면적분포는 산림지(58.6%), 나지(23.3%), 초지(17.6%), 습지(0.5%) 순으로 나타났다. 학습자료의 분광분포 분석결과, 8bit RGB 영상과 16bit MS 영상 모두에서 토양과 인공구조물로 구성된 나지 지역이 가시광선 영역에서 가장 높은 반사율을 보였다. 반면 습지는 물의 강한 흡수특성으로 인해 가시광선 및 근적외선 영역 전반에 걸쳐 가장 낮은 분광값을 나타냈다. 8bit RGB 영상의 경우, 모든 범주에서 Green 밴드의 반사도가 가장 높았으며, 특히 나지 지역에서 Red, Green, Blue 밴드 모두 높은 반사율을 보였다. 나지 지역은 다른 범주와 비교하여 16bit MS 영상기준, 가시광선 대역에서 약 2배 이상 높은 표준편차를 보였는데, 이는 나지에 포함된 토양, 암석, 인공구조물 등 다양한 피복물의 상이한 반사특성에 기인한 것으로 판단된다. Red-Edge와 Near Infrared (NIR) 밴드의 경우, 산림지와 초지의 구분에 효과적인 것으로 분석되었으며, 이는 산림지(Red-Edge 평균 19,665, NIR 평균 17,264)와 초지(Red-Edge 평균 14,766, NIR 평균 13,168) 간의 뚜렷한 분광값 차이에서 확인할 수 있다. 산림지와 초지의 Red-Edge와 NIR 밴드에서 나타난 높은 표준편차는 식생 밀도에 의한 차이와 수종의 다양성에 기인한 것으로 판단된다. 지형정보는 산림지와 초지의 경우, Digital Surface Model (DSM)과 Slope 모두 타 범주보다 높은 분포를 보였으나, 나지와 습지는 반대로 낮은 분포를 보였다. 특히 습지의



경우 DSM과 경사도에서 가장 낮은 표준편차를 보여, 지형적으로 가장 균질한 특성을 보였다 (표 2, 그림 3).

2. 딥러닝 모델의 학습 및 검증

데이터세트 구성에 따른 딥러닝 모델의 학습 및 검증 결과, 8bit RGB 3밴드 모델(Dataset

TABLE 2. Spectral characteristics by land cover categories from training data

Image	Band	Category			
		Forest	Grassland	Bare Land	Wetland
8bit RGB Image	Red	69±52	50±41	137±61	52±23
	Green	85±52	70±39	139±54	56±19
	Blue	59±38	51±27	133±50	37±18
16bit MS Image	Red	7,237±6,030	4,617±4,407	15,864±12,521	2,983±1,438
	Green	12,457±9,288	9,183±6,629	22,180±14,334	5,580±1,918
	Red-Edge	19,665±13,696	14,766±10,522	20,121±11,541	4,758±2,881
	NIR	17,263±10,357	13,168±9,378	14,168±7,835	3,165±1,801
	DSM(m)	205±56	207±46	171±29	150±0.2
	Slope(°)	43±21	41±21	28±21	9±8

Band values are presented as mean ± standard deviation

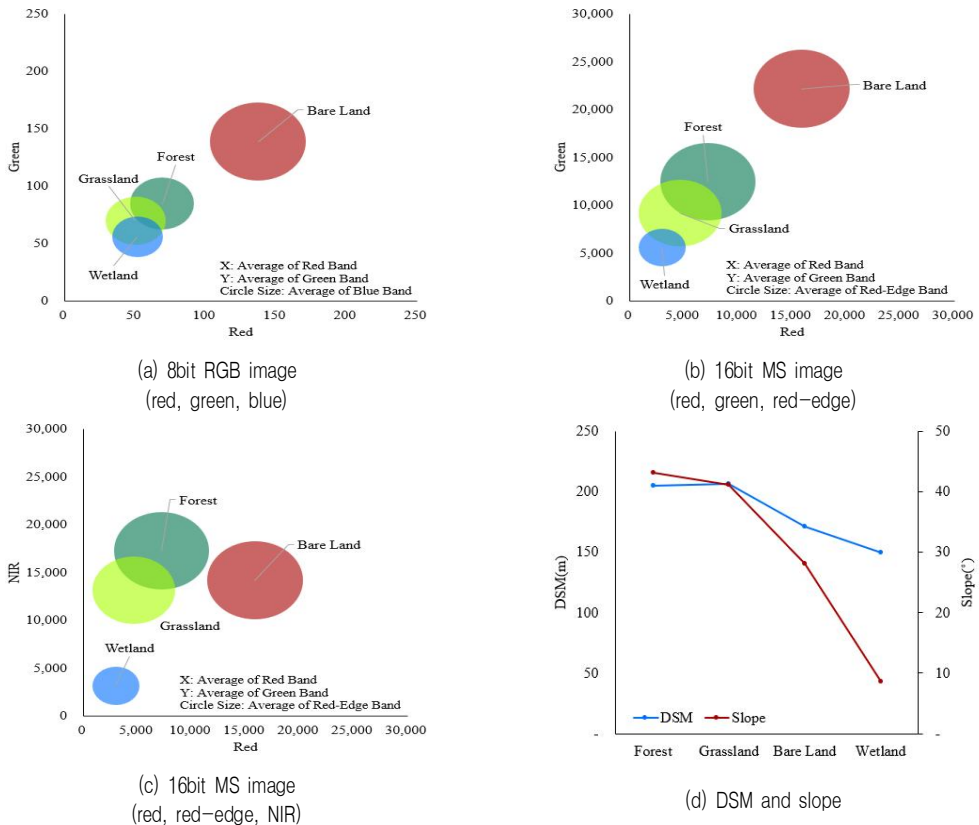


FIGURE 3. Spectral characteristics of training data

A)은 초기 검증 정확도 24.7%에서 시작하여 빠른 학습을 보이며, 최종적으로 훈련 정확도 91.1%, 검증 정확도 92.0%를 달성했다. Red-Edge와 NIR 밴드를 추가한 8bit 4밴드 모델(Dataset B)은 초기 검증 정확도가 45.0%로 더 높았으나, 최종 훈련 정확도 90.5%, 검증 정확도 88.0%로 3밴드 모델보다 다소 낮은 성능을 보였다. 동일한 4밴드 구성에서 방사해상도를 16bit로 향상시킨 모델(Dataset C)은 초기부터 안정적인 학습 성능을 보이며, 최종 훈련 정확도 91.0%, 검증 정확도 91.2%를 달성했다. 이는 높은 방사해상도가 제공하는 풍부한 분광정보가 분류 성능 향상에 긍정적인 영향을 미쳤음을 시사한다. 반면, DSM과 Slope 정보를 추가한 16bit 6밴드 모델(Dataset D)은 학습 과정에서 검증 정확도가 65.4~90.6% 사이에서 크게 변동하며 불안정한 양상을 보였고, 최종적으로 훈련 정확도 90.0%, 검증 정확도 72.3%로 현저히 저하된 성능을 나타냈다. 특히 Dataset D 모델의 경우, 훈련 정확도와 검증 정확도 간의 큰 차이(약 17.7%p)는 심각한 과적합 문제를 드러내며, 이는 지형정보의 추가가 모델의 일반화 능력을 저해할 수 있음을 보여준

다(표 3). 종합적으로, 16bit의 Red, Green, Red-Edge, NIR 4밴드 모델(D3)이 가장 안정적인 학습 패턴과 검증자료 기준 우수한 분류 성능을 보여 토석채취지 분류과정에서 최적의 데이터셋 구성임을 확인하였다.

### 3. 데이터셋 구성에 따른 딥러닝 기반 분류 지도 구축

데이터셋 별 딥러닝 기반 분류지도는 그림 4와 같이 구축되었다. 라벨 이미지와 딥러닝 기반 분류지도의 범주별 면적 분포를 비교해보면, Dataset A의 분류 결과는 산림지가 11.80ha로 라벨이미지 대비 0.78ha 과대 추정되었고, 초지는 라벨이미지 대비 0.83ha 과소 추정되어 초지와 산림지 간 분류 오차가 가장 두드러졌다. Dataset B는 산림지가 0.45ha 과대추정 되었으며, 초지 -0.31ha, 나지 -0.17ha로 전반적으로 라벨과 유사한 분포를 보였으나, 여전히 산림지의 과대 추정 경향이 관찰되었다. Dataset C는 모든 데이터셋 중 라벨과 가장 유사한 면적 분포를 보였으며, 반면 Dataset D는 산림지 +0.48ha, 초지 -0.50ha로 산림지 과대

TABLE 3. Training and validation results of the deep learning model

Category		Dataset A	Dataset B	Dataset C	Dataset D
Input Data Characteristics	Band	RGB	R,G,RE,NIR	R,G,RE,NIR	R,G,RE,NIR, DSM,Slope
	Radiometric Resolution	8bit	8bit	16bit	16bit
Initial Performance	Training Accuracy	74.2%	71.1%	69.3%	70.6%
	Validation Accuracy	24.7%	45.0%	39.1%	41.9%
Maximum Performance	Training Accuracy	91.1%	90.5%	91.0%	90.0%
	Validation Accuracy	92.4%	91.2%	92.0%	90.6%
		(Epoch 80)	(Epoch 72)	(Epoch 61)	(Epoch 98)
Final Performance	Training Accuracy	91.1%	90.5%	91.0%	90.0%
	Validation Accuracy	92.0%	88.0%	91.2%	72.3%
Model Stability	Validation Accuracy Range	24.7~92.4%	45.0~91.2%	39.1~92.0%	41.9~90.6%
	Overfitting Degree*	0.9%p	2.5%p	0.2%p	17.7%p

\* Overfitting Degree: Difference between final training accuracy and validation accuracy (percentage point)

추정과 초지 과소 추정 경향을 보였으며, 습지도 라벨이미지 대비 약 2배 과대 추정되었다. 전반적으로 산림지의 과대 추정과 초지의 과소 추정이 공통적인 오차 요인으로 나타났으며, Dataset C가 이러한 오차를 가장 효과적으로 최소화한 것으로 판단된다(표 4).

한편, MS영상을 활용한 Dataset B, C, D는

공통적으로 그림자가 있는 나지 지역을 습지로 오분류하는 현상이 발생하였다. RGB 영상의 경우, 그림자 영역의 나지는 일반 나지와 비교하여 Red 값이 약 2.5배, Green과 Blue 값이 약 1.2~1.7배 낮게 나타났다. 다중분광 영상에서는 그림자 영역의 나지가 일반 나지에 비해 NIR 값이 약 6배, Red와 Green 값이 약 4~5배 낮은

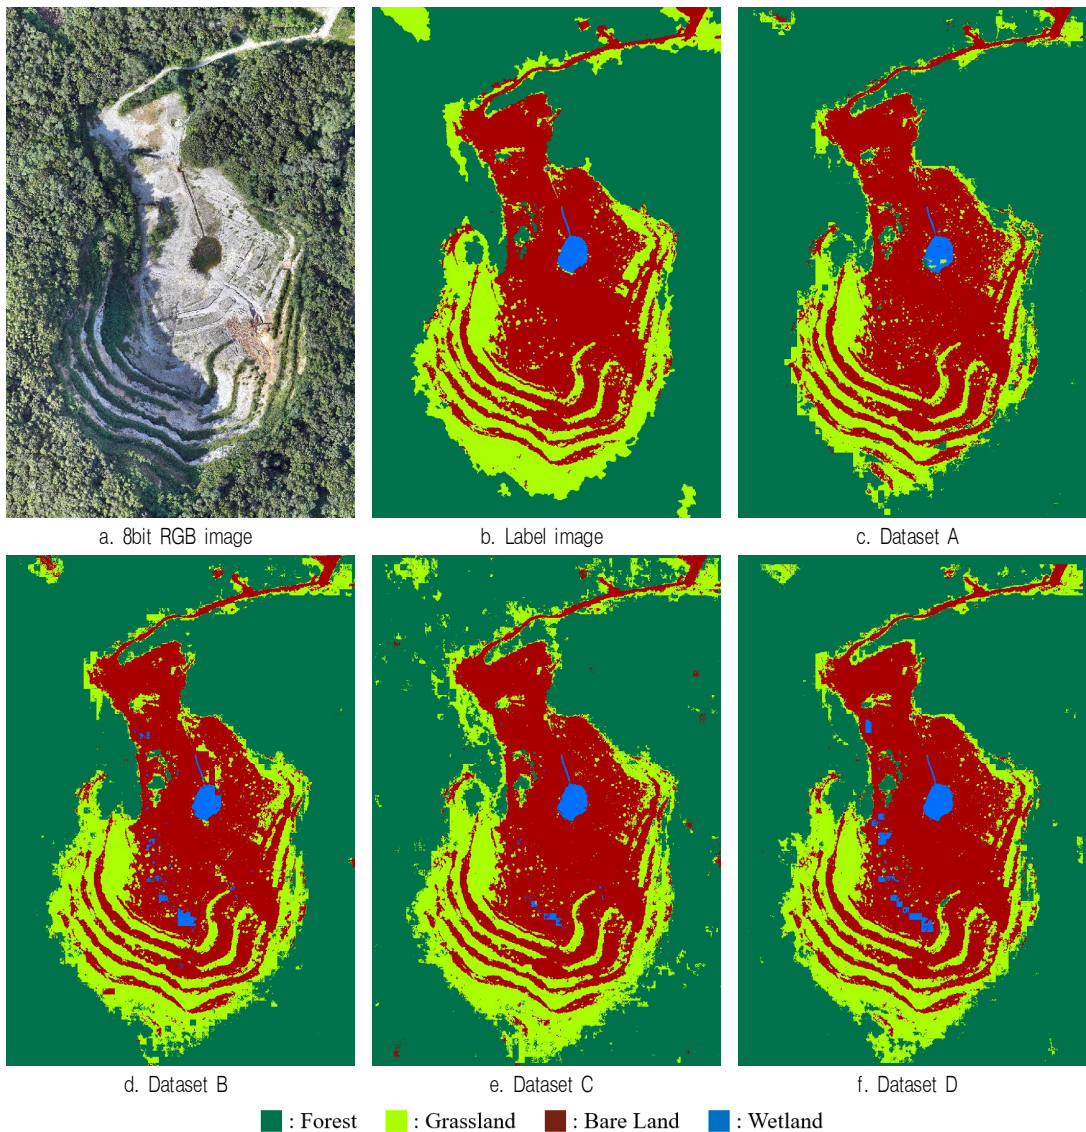


FIGURE 4. Deep learning-based classification maps by dataset

TABLE 4. Area distribution by category in deep learning-based classification maps

Category	Label Image	Deep Learning-Based Classification Map			
		Dataset A	Dataset B	Dataset C	Dataset D
Forest	11.02(58.6%)	11.80(62.8%)	11.47(61.0%)	10.78(57.3%)	11.50(61.1%)
Grassland	3.30(17.6%)	2.47(13.2%)	2.99(15.9%)	3.47(18.5%)	2.80(14.9%)
Bare Land	4.38(23.3%)	4.44(23.6%)	4.21(22.4%)	4.44(23.6%)	4.34(23.1%)
Wetland	0.09(0.5%)	0.08(0.4%)	0.14(0.7%)	0.11(0.6%)	0.17(0.9%)

Unit : ha

분포를 보였다. 이러한 특성으로 인해 MS영상이 RGB 영상보다 그림자의 영향을 더 많이 받았으며, 특히 NIR 파장의 그림자 민감도가 높아 해당 지역이 습지로 오분류된 것으로 판단된다.

#### 4. 딥러닝 기반 분류지도의 정확도 평가

라벨 이미지와 데이터셋 별 딥러닝 기반 분류지도의 혼동행렬 작성을 통한 정확도 비교 결과, 데이터셋 간 전체 정확도(Overall Accuracy, OA)는 92.3~93.0% 범위로 유사한 수준을 보였다(표 5). Dataset B가 OA기준 93.0%로 가장 높은 정확도를 보였으며, Kappa 계수에서도 NIR 파장이 추가된 Dataset B와 Dataset C가 Dataset A 대비 소폭 향상된 값을 나타냈다. 이러한 점으로 볼 때 NIR 파장의 활용은 RGB 영상 대비 분류정확도 향상에 기여하는 것으로 판단된다.

입력 데이터의 특성별 영향을 분석해보면, 8bit RGB 3밴드로 구성된 Dataset A 대비 Red-Edge와 NIR 밴드를 추가한 Dataset B의 성능 향상이 제한적(OA 기준 0.7%p)으로 나타났다. 다만, 산림지(95.3%→96.4%)와 초지(75.9%→80.7%)의 F1-Score가 개선되어, Red-Edge와 NIR 밴드가 식생 유형 구분에는

일정 부분 기여하는 것으로 확인되었다. 방사해상도를 16bit로 향상시킨 Dataset C는 전체 정확도 측면에서는 Dataset A, B와 유의미한 차이를 보이지 않았으나, 토석채취지 분류에서 가장 중요한 나지 영역에 대해 94.8%로 전체 데이터셋 중 두번째로 높은 F1-Score를 기록했다. 또한 분류가 상대적으로 어려운 초지에서는 81.0%, 산림지는 95.7%로 가장 높은 성능을 보였으며 식생영역의 분류성능이 우수한 것으로 확인되었다. 반면, DSM과 Slope 등 지형인자를 추가한 Dataset D는 OA가 92.3%로 낮아졌을 뿐만 아니라, 습지의 F1-Score가 69.5%로 급격히 저하되었다. 이는 지형정보의 추가가 오히려 분류 성능을 저하시킬 수 있음을 시사한다.

비용 효율성 측면에서 볼 때, Dataset A는 92.3%의 높은 정확도를 보여 기본적인 토석채취지 분류에는 충분한 성능을 제공할 수 있다. 그러나 나지 영역의 정확한 분류와 식생 유형의 안정적 구분이 요구되는 상황에서는 Dataset C가 더 적합한 것으로 나타났다. 습지의 경우 연구지역 내 차지하는 면적이 매우 작아 F1-Score의 차이가 실질적인 의미를 가지기는 어려우나, MS 영상을 활용한 데이터셋 중에

TABLE 5. Accuracy assessment of deep learning-based classification maps

Dataset	Overall Accuracy	Kappa	F1-Score			
			Forest	Grassland	Bare Land	Wetland
Dataset A	92.3%	0.861	95.3%	75.9%	95.2%	93.3%
Dataset B	93.0%	0.876	96.4%	80.7%	94.0%	71.6%
Dataset C	92.8%	0.875	95.7%	81.0%	94.8%	87.4%
Dataset D	92.3%	0.863	95.7%	78.5%	93.8%	69.5%

서는 Dataset C가 87.4%로 가장 높은 값을 보였다. MS 영상 기반 데이터셋들은 그림자에 대한 민감도가 더 높아 인해 일부 나지 영역이 습지로 오분류되는 현상이 발생했으나, 연구대상지 내부의 실제 침사지 영역에서는 Dataset B, C, D 모두 RGB 영상 기반의 Dataset A보다 더 정확한 분류 결과를 보였다(그림 4). 이러한 결과는 16bit의 높은 방사해상도와 Red-Edge, NIR 밴드의 조합이 토석채취지 주변의 다양한 토지피복을 분류하는 데 있어 안정적인 성능을 제공할 수 있음을 시사한다.

Dataset C의 분류결과를 중심으로 혼동행렬을 분석한 결과, 주로 산림지↔초지 간 오분류와 초지→나지 오분류가 빈번하게 발생하였다(표 6). 산림지를 초지로 오분류한 사례는 그림 5-1과 같이 주로 토석채취장 주변 산지와 같이

고도차가 큰 지역에서 발생하였다. 이는 계단식 채석 등으로 인한 급격한 지형변화로 인해 동일 산림지역이라도 공간적 특성이 상이하게 나타나기 때문으로 판단된다. 또한 초지 범주에 초본류뿐만 아니라 관목 등 상대적으로 수고가 낮은 임목이 포함되어 있어, 분광특성만으로는 정확한 구분이 어려운 것으로 보인다. 초지를 산림지로 오분류한 사례는 그림 5-2와 같이 숲틈 지역에서 주로 관찰되었다. 이는 산림 내부의 미세한 고도차와 그로 인한 음영 효과가 분류 정확도에 영향을 미친 것으로 해석된다. 이러한 지형적 특성으로 인한 오분류를 개선하고자 Dataset D에서는 DSM과 Slope 정보를 추가하였으나, 오히려 전반적인 분류 성능이 저하되는 결과를 보였다. 이는 지형정보가 클래스 간 경계를 모호하게 만들거나, 동일 클래스 내 지형

TABLE 6. Confusion matrix of deep learning model

Category		Label Image				Total	F1-Score
		Forest	Grassland	Bare Land	Wetland		
Deep Learning Result	Forest	10.43	0.33	0.01	-	10.78	95.7%
	Grassland	0.56	2.74	0.17	0.00	3.47	81.0%
	Bare land	0.03	0.23	4.18	0.00	4.44	94.8%
	Wetland	-	0.00	0.02	0.09	0.11	87.4%
	Total	11.02	3.30	4.38	0.09	18.80	

Overall Accuracy : 92.8%, Kappa : 0.875

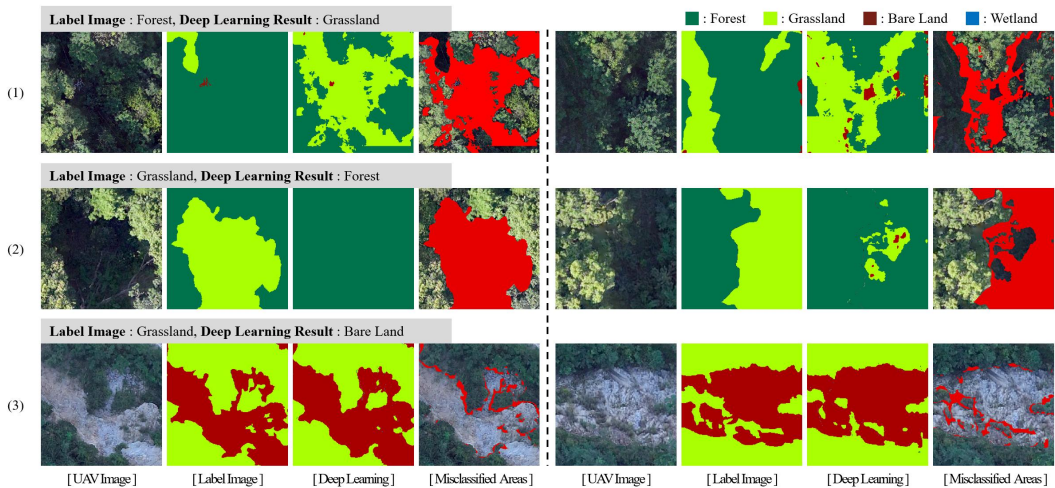


FIGURE 5. Analysis of misclassification in deep learning-based classification maps

적 이질성을 증가시켜 모델의 학습을 방해했을 가능성을 시사한다. 초지와 나지 간 오분류는 그림 5-3과 같이 주로 두 클래스의 경계부에서 집중적으로 발생하였다. 이는 경계부에서 발생하는 점진적인 토지피복의 변화와 혼재된 분광 특성으로 인한 것으로 판단된다. 이러한 경계부의 오분류는 Majority 필터링과 같은 공간적 후처리 기법을 적용함으로써 개선될 수 있을 것으로 기대된다. 향후 연구에서는 지형정보를 직접적으로 입력하는 대신, 지형특성을 고려한 데이터 증강 기법으로 경사도별 영상 회전, 고도별 명암 조정, 그리고 지형 기복에 따른 그림자 효과 시뮬레이션 등을 적용하는 방법의 검토가 필요할 것으로 판단된다. 또한, 모델의 구조적인 측면에서 지형 특성을 효과적으로 학습할 수 있도록 Transformer 모듈의 Attention 메커니즘을 도입하거나, 지형정보를 별도의 인코딩 분기로 처리하는 이중 스트림(dual-stream) 구조 적용 등 다양한 접근방법의 검토가 필요할 것으로 판단된다.

## 결 론

본 연구는 토석채취지 모니터링의 효율적 자동화를 위한 딥러닝 기반 분류 모델의 최적 데이터셋을 선정하고자 하였다. 이를 위해 가시광선 및 멀티스펙트럴 데이터의 분광정보 구성과 방사해상도를 고려한 네 가지 데이터셋을 구성하고, HRNetV2 모델을 통해 분류 정확도를 비교·분석하였다. 연구 결과, 16bit MS 영상의 Red-Edge와 NIR 밴드가 산림지와 초지의 구분에 효과적인 것으로 나타났으며, Dataset C(16bit Red, Green, Red-Edge, NIR)가 전체 정확도 92.8%, Kappa 계수 0.875로 가장 안정적이고 균형 잡힌 분류 성능을 보였다. 특히 다른 데이터셋에서 낮은 정확도를 보인 초지(81.0%)와 습지(87.4%) 분류에서도 우수한 성능을 나타냈다. 반면, DSM과 Slope 정보를 추가한 Dataset D는 과적합 문제가 발생하여 모델의 일반화 능력이 저하되었다. 주요 오분류는 급격한 지형변화 지역의 산림지

↔초지 간 혼동과 토지피복 경계부의 초지→나지 오분류로 나타났으며, 이는 계단식 채석 등으로 인한 급격한 지형변화와 경계부의 점진적인 토지피복 변화에 기인한 것으로 판단된다. 이러한 오분류는 Majority 필터링과 같은 공간적 후처리 기법이나 지형특성을 고려한 데이터 증강, 모델 구조 개선 등을 통해 개선될 수 있을 것으로 기대된다. 본 연구는 분광정보 구성, 방사해상도에 따른 차이, 지형정보의 추가활용 등 데이터셋 구성에 따른 토석채취지 분류 정확도 향상 여부를 검토하였으며, 이러한 최적 데이터셋 구성에 대한 연구결과는 향후 토석채취지 자동 분류 시스템 개발을 위한 기초자료로 활용될 수 있을 것으로 판단된다. 한편, 본 연구의 결과는 토석채취장 1개소를 대상으로 도출된 것이기 때문에 지역적 특성이나 계절적 변화가 분류 성능에 미치는 영향을 고려할 필요가 있다. 따라서 향후 연구에서는 다양한 시기와 지역의 토석채취지에 대한 검증을 통해 모델의 일반화 가능성을 검토하고, 시계열 분석을 통한 토석채취지의 변화 탐지 등으로 연구를 확장할 필요가 있다. 또한, 다양한 환경 조건에서의 모델 성능을 향상시키기 위해 데이터 증강 기법이나 전이학습 등의 방법론적 개선방안의 검토도 함께 필요할 것으로 판단된다. **KAGIS**

## REFERENCES

- Basu, S., S. Ganguly, S. Mukhopadhyay, R. DiBiano, M. Karki and R. Nemani. 2015. DeepSAT: a learning framework for satellite imagery. In Proceedings of the 23rd SIGSPATIAL international conference on advances in geographic information systems pp. 1-10.
- Cheng, B., B. Xiao, J. Wang, H. Shi, T.S. Huang and L. Zhang. 2020. Higherhrnet: Scale-aware representation learning for bottom-up human pose estimation. In Proceedings of the IEEE/CVF conference

- on computer vision and pattern recognition pp. 5386–5395.
- Choung, Y.J. 2014. Analysis of Land Uses in the Nakdong River Floodplain Using RapidEye Imagery and LiDAR DEM. *Journal of the Korean Association of Geographic Information Studies* 17(4): 189–199 (정윤재. 2014. RapidEye 영상과 LiDAR DEM을 이용한 낙동강 범람원 내 토지 이용 현황 분석. *한국지리정보학회지* 17(4): 189–199).
- Delegido, J., J. Verrelst, L. Alonso and J. Moreno. 2011. Evaluation of sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content. *Sensors* 11(7): 7063–7081.
- FAO, F. 2010. Global forest resources assessment 2010: main report. FAO Forestry Paper 163.
- Garcia-Garcia, A., S. Orts-Escolano, S. Oprea, V. Villena-Martinez and J. Garcia-Rodriguez. 2017. A review on deep learning techniques applied to semantic segmentation. *arXiv preprint arXiv:1704.06857*.
- Gärtner, P., M. Förster, A. Kurban and B. Kleinschmit. 2014. Object based change detection of Central Asian Tugai vegetation with very high spatial resolution satellite imagery. *International Journal of Applied Earth Observation and Geoinformation* 31:110–121.
- Huang, M.H. and R.T. Rust. 2018. Artificial intelligence in service. *Journal of service research* 21(2):155–172.
- Im, J., J. Rhee and J. R. Jensen. 2009. Enhancing binary change detection performance using a moving threshold window (MTW) approach. *Photogrammetric Engineering & Remote Sensing* 75(8): 951–961.
- Kwon, S.K., E.H. Kim, J.B. Lim and A.R. Yang. 2021. The Analysis of Changes in Forest Status and Deforestation of North Korea's DMZ Using RapidEye Satellite Imagery and Google Earth. *Journal of the Korean Association of Geographic Information Studies* 24(4):113–126 (권수경, 김은희, 임중빈, 양아람. 2021. RapidEye 위성영상과 구글 어스를 활용한 북한 DMZ의 산림현황 및 산림황폐지 변화 분석. *한국지리정보학회지* 24(4):113–126).
- LeCun, Y. 1989. Generalization and network design strategies. in *Connectionism Perspective*. Elsevier pp. 143–155.
- Li, L., Q. Yang, R. Shi and J. Teng. 2023. MSCR-HRNetV2: High-Resolution Remote Sensing Image Segmentation for Railway Scenes. In *2023 China Automation Congress (CAC)* pp. 5809–5814. IEEE.
- Lin, T., P. Goyal, R.B. Girshick, K. He and P. Dollár. 2017. Focal Loss for Dense Object Detection. *2017 IEEE International Conference on Computer Vision* pp. 2999–3007.
- Liu, D. and F. Xia. 2010. Assessing object-based classification: advantages and limitations. *Remote sensing letters* 1(4):187–194.
- Loshchilov, I. and F. Hutter. 2017. Fixing weight decay regularization in adam. *arXiv preprint arXiv: 1711.05101*.
- Milletari, F., N. Navab and S. A. Ahmadi. 2016. V-net: Fully convolutional neural networks for volumetric medical image segmentation. In *2016 fourth international*

- conference on 3D vision (3DV) pp. 565–571. Ieee.
- Návar, J. 2015. Changes in Forest Production, Biomass and Carbon: Results From the 2015 UN FAO Global Forest Resource Assessment. *Forest Ecology and Management* 352:21–34.
- Park, J.H., K.D. Kim and M.J. Kang. 2016. Analysis of Quarrying and Restoration Characteristics on Quarry in Korea. *Journal of Korean Society of Forest Science* 105(2):223–230 (박재현, 김기대, 강민정. 2016. 국내 토석사업장의 토석채취 및 복구특성 분석. *한국산림과학회지* 105(2):223–230).
- Park, J.H., C.M. Park and J.W. Lee. 2010. Analysis of the Restoration Actual Conditions on the Quarries. *Journal of the Korean Society of Environmental Restoration Technology* 13(3):128–142 (박재현, 박종민, 이준우. 2010. 토석채취지의 복구 실태 분석. *한국환경복원기술학회지* 13(3):128–142).
- Park, J.H. 2012. Analysis of the Restoration Actual Conditions on the Quarries II. *Journal of Korean Forest Society* 101(4):558–566 (박재현. 2012. 토석채취지의 복구 실태 분석 II. *한국산림과학회지* 101(4):558–566).
- Park, J.H. and T.R. Kim. 2021. Analysis of Drone Surveying Using a Low-Cost PPK Kit. *Journal of the Korean geomorphological association* 28(4):41–52 (박준호, 김태림. 2021. PPK Kit를 활용한 드론 측량분석. *한국지형학회지* 28(4): 41–52).
- Rouhi, R., M. Jafari, S. Kasaei and P. Keshavarzian. 2015. Benign and malignant breast tumors classification based on region growing and CNN segmentation. *Expert Systems with Applications* 42(3): 990–1002.
- Rouse, J.W., R.H. Haas, J.A. Schell and D.W. Deering. 1974. Monitoring vegetation systems in the Great Plains with ERTS. *NASA Spec. Publ* 351(1): 309.
- Schöpfer, E., S. Lang and J. Strobl. 2010. Segmentation and object-based image analysis. *Remote sensing of urban and suburban areas* 181–192.
- Smith, L.N. and N. Topin. 2019. Super-convergence: Very fast training of neural networks using large learning rates. In *Artificial intelligence and machine learning for multi-domain operations applications*. pp. 369–386. SPIE.
- Sun, K., B. Xiao, D. Liu and J. Wang. 2019. Deep high-resolution representation learning for human pose estimation. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* pp. 5693–5703.
- Wang, J., K. Sun, T. Cheng, B. Jiang, C. Deng, Y. Zhao, D. Liu, Y. Mu, M. Tan, X. Wang, W. Liu and B. Xiao. 2020. Deep high-resolution representation learning for visual recognition. *IEEE transactions on pattern analysis and machine intelligence* 43(10):3349–3364.
- Wang, Z., E.P. Simoncelli and A.C. Bovik. 2003. Multiscale structural similarity for image quality assessment. In *The Thrity-Seventh Asilomar Conference on Signals, Systems & Computers* pp. 1398–1402.
- Won, M.S., Y.S. Kim and K.H. Kim. 2014. Estimation on Greenhouse Gases(GHGs)



Emission of Large Forest Fire Area in 2013. Journal of the Korean Association of Geographic Information Studies 17(3): 54–67 (원명수, 김유승, 김경하. 2014. RapidEye 영상을 활용한 대형산불피해지의 온실가스 배출량 추정. 한국지리정보학회지 17(3):54–67). 