

# 딥 러닝 기반 이미지 트레이닝을 활용한 하천 공간 내 피복 분류 가능성 검토

## Review of Land Cover Classification Potential in River Spaces Using Satellite Imagery and Deep Learning-Based Image Training Method

강우철<sup>1</sup> · 장은경<sup>1\*</sup>

<sup>1</sup>한국건설기술연구원 수자원하천연구본부 전임연구원

Woochul Kang<sup>1</sup> and Eun-kyung Jang<sup>1\*</sup>

<sup>1</sup>Research Specialist, Department of Land, Water and Environment Research, Korea Institute of Civil Engineering and Building Technology, Goyang 10223, Korea

Received 11 October 2022, revised 6 December 2022, accepted 6 December 2022, published online 31 December 2022

**ABSTRACT:** This study attempted classification through deep learning-based image training for land cover classification in river spaces which is one of the important data for efficient river management. For this purpose, land cover classification analysis with the RGB image of the target section based on the category classification index of major land cover map was conducted by using the learning outcomes from the result of labeling. In addition, land cover classification of the river spaces was performed by unsupervised and supervised classification from Sentinel-2 satellite images provided in an open format, and this was compared with the results of deep learning-based image classification. As a result of the analysis, it showed more accurate prediction results compared to unsupervised classification results, and it presented significantly improved classification results in the case of high-resolution images. The result of this study showed the possibility of classifying water areas and wetlands in the river spaces, and if additional research is performed in the future, the deep learning based image train method for the land cover classification could be used for river management.

**KEYWORDS:** Bayesian deep learning, Image classification, Land cover, River space, Satellite image

**요 약:** 본 연구는 효율적인 하천 관리를 위해 중요한 데이터 중 하나인 하천 공간의 토지피복 분류를 위해 딥 러닝 기반의 이미지 트레이닝 방법의 활용가능성을 검토하였다. 이를 위해 대상 구간의 RGB 이미지를 활용하여 라벨링 작업 후 학습시킨 결과를 활용하여 기존 대분류 지표를 기준으로 토지피복 분류를 시도하였다. 또한 개방형으로 제공되는 Sentinel-2 위성 영상으로부터 무감독 분류 및 감독 분류에 의한 하천 공간의 토지피복 분류를 수행하였으며, 딥 러닝 기반 이미지 분류 결과와 비교하였다. 분석 결과의 경우 무감독 분류 결과와 비교하여 매우 향상된 예측 결과를 보여주었으며, 고해상도 이미지의 경우 더욱 정확한 분류 결과를 제시하였다. 단순한 이미지 라벨링을 통해 분류된 피복 분류 결과는 하천 공간 내 수역과 습지의 분류 가능성을 보여주었으며, 향후 추가적인 연구 수행이 이루어진다면 하천 관리를 위해 딥 러닝 기반 이미지 트레이닝 기법을 이용한 하천 공간내 피복 분류 결과의 활용이 가능할 것으로 판단된다.

**핵심어:** Bayesian Deep Learning, 이미지 분류, 토지피복, 하천 공간, 위성영상

\*Corresponding author: jang@kict.re.kr, ORCID 0000-0002-4925-5018

© Korean Society of Ecology and Infrastructure Engineering. All rights reserved.

This is an open-access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>), which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

## 1. 서론

최근 하천의 생태 환경적 가치를 고려함에 따라 하천 관리의 개념은 이치수 기능만이 아닌 하천 고유의 자연성 보존까지 고려하게 되었으며, 하천 공간에 대한 정의 역시 하천의 생태와 환경을 고려하여 하천을 주체로 하는 모든 공간으로 확대되고 있다 (Woo 2017, Kang et al. 2021a). 국내 하천의 경우 독특한 지형과 여름에 강우가 집중되는 기후 특성의 영향 때문에 하천 공간 내 변화가 많이 발생한다 (Kang et al. 2019, Kang et al. 2021b, Kang et al. 2022a, Kang et al. 2022b). 특히 기후변화로 인해 발생하는 이상 홍수의 빈도와 규모가 더욱 증가함에 따라 하천 내에서의 흐름저항 증가로 인해 유속감소 및 홍수위 증가, 유사량 퇴적 등이 발생하고 있으며, 이로 인해 하천에 발생하는 식생 유입, 홍수터 변화 같은 다양한 하천 공간 변화 등에 대한 주기적인 모니터링과 정략적 분석이 시도되고 있다 (Lee et al. 2010, Kim and Yeom 2012, Lee and Choi 2014, Jo et al. 2019). 하천 공간이 정형화되고 고정된 구역이 아닌 산지나 식생 사주처럼 계절적, 시간적 영향에 의해 동적으로 변화하는 경우 연중 토지피복 형태가 변화하기 때문에 특정 분류 형태에 대해 하천 관리의 영역을 명확히 설정하는 것은 어려운 문제이다. 최근에는 기술 발달에 의해 다양한 위성 영상을 주기적으로 획득이 가능하여 피복분류같이 위성 영상의 수자원 하천 관리를 위해 이용되는 빈도가 계속 증가하고 있다 (Kang et al. 2021a). 국내의 경우 위성에서 연간 취득한 자료를 바탕으로 토지피복 현황을 제공하고 있지만 이를 시간의 흐름을 고려하여 계절적 영향을 반영하는데 한계가 있으며, 직접 분석을 하는 경우에도 다중 분광 위성영상을 원하는 시기의 자료를 얻는데 경제적, 기술적 제약이 존재한다. 하지만 일반적인 RGB 이미지는 항공, 드론, CCTV를 통해 시간적, 공간적 제약에서 좀 더 자유롭게 데이터를 취득할 수 있으며, 이러한 데이터를 하천 공간 토지피복 분석에 활용할 수 있다면 하천 공간 관리의 고도화를 기대할 수 있다. 특히 최근 활발하게 응용되는 딥 러닝 분석과 더불어 좌표 및 추가적인 분광 정보를 내포하지 않은 단순 이미지의 트레이닝을 통해 하천 공간의 피복 분류가 가능하다면 효율적인 하천 관리에 도움이 될 것으로 판단된다. 따라서 본 연구에서는 금강의 일부 하천 공간을 대상으로 딥 러닝 기반의 이미지 트레이닝 방법을 이용하여 토지피복을 분류한

후 동일한 시기의 Sentinel-2 위성 영상으로부터 무감독 분류와 감독 분류 기법을 적용하여 얻은 토지피복 분류 결과와 비교 분석을 수행하였다. 이를 통해 하천 공간의 관리에 효과적인 기여하기 위한 딥 러닝 기반 이미지 분류 기술의 활용 가능성을 검토하였다.

## 2. 연구 방법 및 자료 수집

### 2.1 대상구간 개요

본 연구의 목적은 하천 공간의 피복 분류를 분석하기 위해 단순 RGB 이미지로부터 딥 러닝 기반 이미지 분류의 가능성을 검토하는 것이며, 이를 위해 식생분포, 범람원, 수역의 구분을 요구하는 불특정 구간을 대상구간으로 선정하고자 하였다. 금강 유역의 용담댐 하류부터 대청댐 상류 구간의 경우 자연성 기반 홍수터 복원 시범 사업이 예정되어 있으며, 이에 따라 제내지의 토지 이용도 분석이 필수적으로 요구되는 구간이다. 또한 하천 구간의 토지피복 분석을 위해 시가화/건조, 농업, 산림, 초지, 습지, 나지 수역 등 대분류가 적절히 분포되어 있는 구간으로 선정하고자 하였으며, 최종적으로 제원대교 상류 장동리 인근 만곡 구간을 대상구간으로 선정하였다 (Fig. 1).

### 2.2 대상구간 토지피복 분석

환경부에서 주기적으로 제공하는 대분류 토지피복의 경우 7가지 분류 체계를 가지고 있으며 각각의 체계와 코드는 시가화/건조 (100), 농업 (200), 산림 (300),

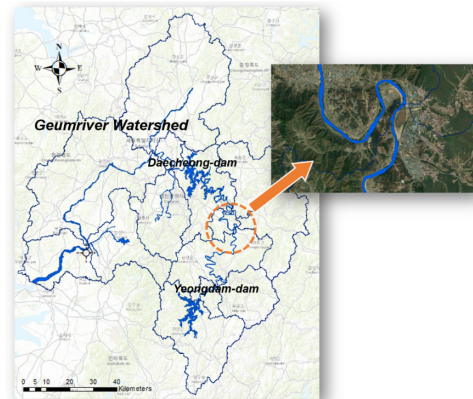


Fig. 1. Watershed map and detailed image of the target section of Geumriver Watershed.




Fig. 2. Study area of (a) satellite image from ESRI 2022; and (b) land cover map.

초지 (400), 습지 (500), 나지 (600), 수역 (700)으로 각각 분류된다 (Fig. 2).

하천 공간의 경우 강우나 유사의 유입, 퇴적 조건에 따라 변화되기 때문에 하천 공간 내의 위성 이미지 (Fig. 2 (a))과 토지피복지도 (Fig. 2 (b))를 비교해봐도 차이를 확인할 수 있으며, 결국 연단위로 제공되는 토지피복지도로부터 하천 공간에 대한 정확한 정보를 획득하기 어려움이 있다. 따라서 본 연구에서는 앞서 언급한 딥 러닝 기반 이미지 트레이닝 방법을 이용한 하천 공간의 피복 분류 가능성을 검토하기 위해 비슷한 시기의 RGB 이미지를 대상으로 대분류 토지피복의 분류체계를 적용하여 이미지 트레이닝을 수행한 후 위성 영상의 RGB 이미지를 대상으로 피복 분류를 수행하였다. 또한 딥 러닝 기법의 결과를 비교 분석하기 위해 동일한 위성영상의 다중 분광 이미지를 대상으로 감독 분류와 무감독분류를 수행하였다. 분석을 위해 이용된 위성 영상은 유럽연합 코페르니쿠스 지구 관측 프로그램의 일환으로 개발된 Sentinel-2를 이용하였다. 해당 위성의 경우 5일마다 지구 표면의 각 지점을 재방문이 가능하며, 폭넓은 다중 스펙트럼 장치를 탑재하고 있기 때문에 가시광선과 적외선 사이의 13개 대역에 걸쳐 픽셀당 최소 60 m에서 최대 10 m의 정밀도로 영상 정보를 무료로 제공한다. 대상 구간의 하천 공간 피복 분석을 수행하기 위해 방사, 기하, 정사 보정 및 공간 정합이 이루어진 Sentinel-2 L1C (Level 1C) 자료를 이용하였으며, 위성 영상의 경우 피복 분류 결과와 하천환경 조건을 고려하여 식생 활착이 비교적 덜 이루어진 2021년 4월 7일 자료를 이용하였다 (Fig. 3).




Fig. 3. Sentinel-2 satellite image of study area.

위성 영상을 이용한 토지피복 분류의 경우 각각의 화소에 대해 분광학적으로 유사한 클래스를 할당하는 방식을 이용하며, 처리 방법에 따라 감독 분류 (Supervised Classification)와 무감독 분류 (Unsupervised Classification)로 구분된다. 연구 대상 지역의 하천 공간 피복 분석을 위해 무감독 분류 방법 중 하나인 K-means method와 감독 분류 중 가장 일반적인 분류 방법인 Maximum likelihood classification을 이용하였다. K-means method 분류 방법의 경우 후보 클러스터 중심으로 사용하기 위해 대분류 피복 분류 체계와 같은 7개의 분류 기준을 선택하여 클러스터 중심의 이동이 없을 때까지 각 화소에 대해 가장 가까이에 위치한 클러스트로 할당하여 분류가 이루어진다. Maximum likelihood classification의 경우 각 픽셀은 정규분포로 가정 아래 7가지 항목에 대한 훈련데이터의 평균 벡터와 공분산 행렬을 이용하여 분류가 수행된다. 본 연구에서는 위성 영상으로부터 하천 공간 내 토지피복 분류를 위해 지리 공간 이미지를 시각화, 처리 및 분석하는 데 사용되는 소프트웨어 프로그램인 ENVI (V. 5.6)를 이용하였다.

### 2.3 신경망학습을 통한 이미지 분류 과정

인공신경망(ANN)이라고도 하는 신경망은 기계 학습(machine learning)의 일부이며, 현재의 딥 러닝 알고리즘의 핵심이라고도 할 수 있다. 이러한 신경망 구조는 이미지 인식이나 분류와 같은 신경망의 구조로 진화하였으며 보다 실용적인 유스케이스로 발전하였다. 본 연구에서는 하천의 이미지 데이터 분류를 위해 신경망 학습 방법 중 Bayesian Deep Learning 기반 모델을 활용하였다. 트레이닝되는 이미지는 많으면 많을수록 정확도 향상에 기여하기 때문에 공개적으로 사용이 가

능한 2008년부터 2020년까지 용담댐 하류부터 대청댐 상류 구간에서 촬영된 이미지를 무작위로 Fig. 4와 같이 추출하여 다량의 데이터를 트레이닝에 활용하였다.

이미지 트레이닝을 위해 토지피복 대분류에서 활용되는 7가지 분류 기준을 적용하였으며, 각각의 대분류 지표를 통한 분류 라벨링의 예는 Fig. 5와 같다. 또한 분류 성과를 정량화하기 딥 러닝 성능 평가를 위해 가장 많이 활용되고 있는 분류성능평가지표 중 정밀도와 재현율을 확인하였다. 7가지 대분류 토지피복 지표 중에서 농경지 수역의 정밀도와 재현율이 가장 높은 것으로 평가되었다(Table 1).



Fig. 4. Aerial orthogonal video sample image of the target section.



Fig. 5. Example of labeling for image training with seven classification schemes of large classification land cover.

Table 1. Classification performance evaluation index for Bayesian deep learning application by each classification land cover

| Class       | Code | Precision | Recall |
|-------------|------|-----------|--------|
| Urban       | 100  | 0.1       | 0.03   |
| Agriculture | 200  | 0.62      | 0.4    |
| Forest      | 300  | 0.32      | 0.36   |
| Pasture     | 400  | 0.23      | 0.1    |
| Wetland     | 500  | 0.05      | 0.11   |
| Bare land   | 600  | 0.19      | 0.11   |
| Water       | 700  | 0.39      | 0.22   |

### 3. 하천 공간의 토지피복 분류 결과

#### 3.1 위성 영상을 활용한 무감독 및 감독 분류 분석

본 연구에서는 딥 러닝 기반 이미지 분류 방법을 이용하여 하천 구간내 피복 분류정보의 획득 가능성을 평가하기 위해 장동리 일대의 위성 영상으로부터 전체 구역

에 대해 피복 분류를 수행한 후 제방 선을 따라 하천 구간을 설정한 이후 해당 구간에 대한 결과를 획득하였다. 먼저 설정한 하천 공간에 대한 환경부에서 제공된 토지피복도의 피복 분류 결과는 Fig. 6과 같으며, 연구 대상 지역의 하천 공간(전체 면적: 0.865 km<sup>2</sup>)을 대상으로 7가지 분류 지표들의 면적과 비율은 Table 2와 같다.

환경부 대분류 토지피복지도에서도 확인할 수 있듯




Fig. 6. Result of land cover classification using land cover map.

Table 2. Comparison of land cover classification results using existing land coverage

| Class       | Code | Land Cover Map          |                | Maximum likelihood classification |                |
|-------------|------|-------------------------|----------------|-----------------------------------|----------------|
|             |      | Area [km <sup>2</sup> ] | Percentage [%] | Area [km <sup>2</sup> ]           | Percentage [%] |
| Urban       | 100  | 0.021                   | 2.43           | 0.070                             | 8.08           |
| Agriculture | 200  | 0.049                   | 5.67           | 0.020                             | 2.33           |
| Forest      | 300  | 0.008                   | 0.93           | 0.012                             | 1.44           |
| Pasture     | 400  | 0.276                   | 31.94          | 0.339                             | 39.19          |
| Wetland     | 500  | 0.118                   | 13.66          | 0.086                             | 9.96           |
| Bare land   | 600  | 0.011                   | 1.27           | 0.000                             | 0.00           |
| Water       | 700  | 0.382                   | 44.21          | 0.337                             | 38.97          |
| Total       |      | 0.865                   | 100            | 0.865                             | 100            |

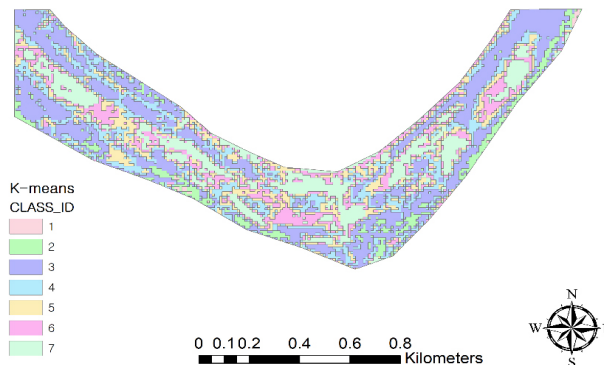


Fig. 7. Result of land cover classification using the K-means method.

이 하천 공간의 경우 대부분이 수역, 초지, 늪지로 분류되며, 구조물의 유무와 하천 공간의 활용 방법에 따라 시가화, 농지 지역이 비율이 일부 차지 하는 것으로 판단된다. 다음으로 훈련 데이터 없이 피복 분류가 가능한 무감독 분류 방법을 이용하여 7개를 분류한 결과는 Fig. 7과 같다.

해당 방법의 경우 훈련 데이터가 없이 매우 간단히 분류되는 장점이 있지만, 분류 결과로부터 유의미한 정보를 획득하는 것은 불가능 하였다. 감독 분류 중 하나인 Maximum likelihood classification 방법을 수행하기 위해서 위성 영상으로부터 7개의 분류 기준에 대하여 전체 면적의 약 20% 대상으로 훈련영역 (training areas)을 지정하였다. 장동리 일대 지역 전체를 대상으로 분류 결과의 Overall accuracy는 97.43% 이며 계통 표집과 임의표집에 대한 Kappa coefficient 값은 0.957로 매우 정확한 분류 결과를 얻었다 (Table 3). 훈련 영역으로부터 각 클래스에 대한 스펙트럼적으로 유사한 영역을 인식하여 하천 공간내 피복 분류를 한 결과는 Fig. 8과 같다.


감독 분류 방법을 이용한 피복 분류 결과의 경우 토지피복 지도와는 차이가 있음을 보여주었다 (Table 2). 이러한 차이는 토지피복 지도의 경우 보다 정확한 분류를 위해 고해상도 자료와 현장조사를 기반으로 분류를 수행하는 반면 본 연구에서는 오직 10 m 해상도의 위성 영상에 대한 다중 분광 정보를 기반으로 수행하였기 때문에 제방 및 교량으로 분류된 시가화 지역에 대한 분류 결과가 과대 선정된 것으로 판단된다. 하지만 해상도와 현장조사의 유무와는 관계없이 수역, 늪지, 초지의 비율이 달라지는 것은 영상의 시간적 차이로부터 생긴 것으로 보이며, 이러한 결과는 토지피복 지도를 하천 공간 정보를 얻기 위해 바로 이용하는 것이 바람직하지 않다는 것을 보여준다.

### 3.2 Deep-learning 기반 이미지 트레이닝 기법을 활용한 피복 분류 결과


2장에서 수집된 무작위 대용량 이미지 라벨링 후 학습된 결과를 이용하여 장동리 인근을 대상으로 이미지

**Table 3.** Accuracy assessment of classification result using the maximum likelihood classification

|                 | Code | Training set data (Known cover type, [%]) |       |       |       |     |     |       | Total |
|-----------------|------|---|-------|-------|-------|-----|-----|-------|-------|
|                 |      | 100                                       | 200   | 300   | 400   | 500 | 600 | 700   |       |
| Validations [%] | 100  | 75.44                                     | 12.96 | -     | 0.61  | -   | -   | 1.32  | 2.15  |
|                 | 200  | 21.05                                     | 68.52 | 0.28  | -     | -   | -   | 1.85  | 2.4   |
|                 | 300  | -   | -     | 99.22 | -     | -   | -   | -     | 62.58 |
|                 | 400  | -   | 1.85  | 0.5   | 99.39 | -   | -   | -     | 6.06  |
|                 | 500  | 3.51                                      | 16.67 | -     | -     | 100 | -   | 0.4   | 0.7   |
|                 | 600  | -   | -     | -     | -     | -   | 100 | -     | 0.35  |
|                 | 700  | -   | -     | -     | -     | -   | -   | 96.44 | 25.76 |
| Total           |      | 100                                       | 100   | 100   | 100   | 100 | 100 | 100   | 100   |



**Fig. 8.** Result of land cover classification using the Maximum likelihood classification.



**Fig. 9.** River image of (a) Sentinel-2 and (b) World imagery (ESRI, 2022); and classification result for model prediction by Bayesian Deep Learning (c) Sentinel-2 and (d) World imagery (ESRI, 2022).

**Table 4.** Result of comparative analysis between image training method and classification result from the maximum likelihood classification

|               | Water                   |                | Wet-land                |                | Total accuracy [%] |
|---------------|-------------------------|----------------|-------------------------|----------------|--------------------|
|               | Area [km <sup>2</sup> ] | Percentage [%] | Area [km <sup>2</sup> ] | Percentage [%] |                    |
| Sentinel-2    | 0.13                    | 38.58          | 0.006                   | 6.8            | 15.72              |
| World imagery | 0.12                    | 35.61          | 0.02                    | 23.26          | 16.18              |

분류를 시도하였다. 구체적으로 앞절에서 이용된 동일한 Sentinel-2 위성 영상으로부터 얻은 RGB 이미지 (Fig. 9 (a))와 ESRI 제공하는 고해상도 RGB 위성 이미지 (Fig. 9 (b))를 활용하였다. 이미지 분류 결과 육안을 통해서도 비교적 구분이 명확한 산지, 농경지에 대해 우수한 분류 결과를 보여주었다. 하천 공간 내 피복 분류의 비교를 위해 딥 러닝 기반 이미지 분류 결과 중 대부분을 차지하는 수역 또는 습지만 비교를 수행하였으며, Maximum likelihood classification로부터 분류된 결과와 비교하여 수역은 35% 이상, 습지 중 10% 이상의 지역이 일치하는 결과를 보여주었다 (Table 4).

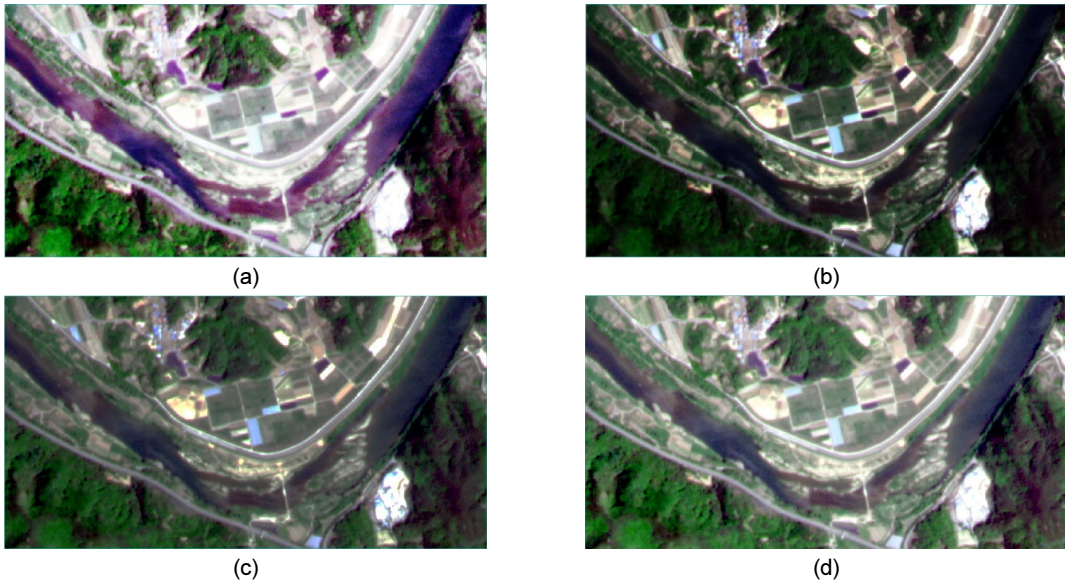
하지만 명확한 구분하기 어려운 하천공간 내 수역과 습지의 경우에는 중복하여 분류되거나 분류가 쉽지 않음을 확인할 수 있다 (Fig. 9). ESRI에서 제공하는 World imagery의 경우 다중 분광 정보가 없기 때문에 Maximum likelihood classification 분석 수행 결과와 직접적인 비교는 불가능 하지만, Sentinel-2 분석 결과와 비

교하여 수역의 경우 비슷한 분류 정확도를 보여주었으며, 습지에 대한 분석의 정확도가 크게 상승하였다 (Fig. 9).


하지만 이러한 분류 결과가 이미지 해상도에 영향이 있는지 아니면 단순 색감 차이에 의한 결과인지 추가적인 분석이 요구된다. 향후 고도화된 하천 관리를 위한 하천 공간 내 피복 분류 결과는 구조물, 식생 혹은 모래사주가 구별과 하천 식생과 삼림으로 구분된 영역이 명확히 될 수 있도록 정교한 작업과 추가적인 연구가 필요할 것으로 판단된다.

#### 4. 이미지 분류 결과 개선을 위한 히스토그램 스트레칭 적용

본 절에서는 영상의 픽셀의 밝기와 명암을 조절하여 영상의 가시도를 좋게 하는 히스토그램 스트레칭이 적용된 RGB 위성 이미지를 이용하여 추가적으로 이미지 분



**Fig. 10.** Satellite images with histogram stretching that improves visibility by adjusting the brightness and contrast of pixels: (a) Equalization (b) Linear (c) Gaussian (d) Square root.



**Fig. 11.** Results of image classification with applied with histogram stretching: (a) Equalization (b) Linear (c) Gaussian (d) Square root.

류 개선을 시도하였다. 다양한 히스토그램 스트레칭 방법 중 1) 히스토그램 빈에서 동일한 수의 디지털 숫자 (DN)를 갖도록 데이터를 확장하는 방법인 Equalization, 2) 최소 및 최대 히스토그램 값의 이미지의 동적 범위를 정의하여 전체 이미지의 픽셀 값을 선형으로 늘려 이미지 가 더 밝게 해줄 수 있는 Linear 방법, 3) 데이터 평균값과 표준편차를 이용하여 중간값에 가우스 곡선을 할당하는

방법인 Gaussian 방법, 4) 히스토그램의 제곱근을 계산하여 linear stretch를 적용하는 Square root 방법들을 sentinel-2 위성 영상에 적용하여 분석에 이용하였다 (Fig. 10).

히스토그램 스트레칭 기법을 적용한 이미지를 대상으로 이미지 분류 결과 (Fig. 11)와 기존의 분류 결과를 비교하면, 명암과 밝기가 조정된 Equalization이 적용



**Table 5.** Result of comparative analysis between image training for histogram stretched and classification result from the maximum likelihood classification

|              | Water                   |                | Wet-land                |                | Total accuracy [%] |
|--------------|-------------------------|----------------|-------------------------|----------------|--------------------|
|              | Area [km <sup>2</sup> ] | Percentage [%] | Area [km <sup>2</sup> ] | Percentage [%] |                    |
| Equalization | 0.143                   | 42.43          | 0.016                   | 18.60          | 18.38              |
| Linear       | 0.106                   | 31.45          | 0.015                   | 17.44          | 13.99              |
| Gaussian     | 0.045                   | 13.35          | 0.018                   | 20.93          | 7.28               |
| Square root  | 0.138                   | 40.95          | 0.113                   | 13.19          | 17.39              |

된 이미지의 경우 보다 정확한 이미지 분류 결과를 보여 준 것을 확인하였다(Table 5). 해당 결과로부터 고해상도 영상을 대상으로 추가적인 보정 결과를 통해 보다 나은 분류 결과를 얻을 수 있을 것이라 판단된다.

## 5. 결론 및 고찰

본 연구에서는 하천 공간의 토지피복 분류를 위해 다중 분광 위성 영상을 이용하여 피복 분류를 수행한 결과와 비교하여 단순 RGB 이미지로부터 Bayesian Deep Learning 이미지 트레이닝 방법을 이용한 피복 분류 가능성을 검토해 보았다. 이를 위해 금강 유역의 장동리 인근 만곡 구간 하천 공간을 대상으로 2021년 4월 7일의 Sentinel-2 위성 영상으로부터 대분류 기준 토지피복 분류 기준으로 무감독 분류와 감독 분류 기법을 적용하여 얻은 결과를 도출하였다. 또한 2008년부터 2020년까지 용담댐 하류부터 대청댐 상류 구간에서 촬영된 RGB 이미지를 무작위로 추출하여 이미지 트레이닝 작업을 수행한 후 앞서 분석에 이용된 위성영상과 고해상도 RGB 위성 이미지를 대상으로 분류를 수행한 결과와 비교 분석 통해 기술의 활용 가능성을 확인하였다.

최근 위성 자료의 경우 개방형으로 전환되고 있으며 영상의 해상도가 역시 증가하고 있는 추세이다. 하지만 여전히 자료를 얻거나 분석하는데 있어 기상조건, 보정 과정, 전문적인 분석 작업 필요 등 어려움이 존재하고 원하는 시기에 자료를 확보하기 어려우며 보다 정확한 고해상도 위성영상을 얻는 데는 많은 비용이 소모된다. 단순 RGB 이미지의 경우 다중 분광의 위성 영상과는 다르게 쉽게 자료를 획득할 수 있다는 뛰어난 장점을 가지고 있기 때문에 딥 러닝 기반의 이미지 트레이닝 기법은 효율적이라 할 수 있으며, 해당 방법의 경우 무감독 분류 결과와 비교하였을 때 충분한 활용 가능성을 보여

주었다. 구체적으로 Sentinel-2 위성 영상을 감독 분류 방법 중 Maximum likelihood classification을 이용하여 분류한 결과와 비교하여 해당 기법의 경우 수역은 약 40% 이상의 비교적 매우 정확한 하천 공간 피복 분류 결과를 보여주었으며, 특히 무감독 분류 방법 중 K-means method을 이용한 분류 결과와 비교한다면 매우 의미 있는 결과를 제시하였다.

딥 러닝 기반 분류의 경우 트레이닝 데이터를 꾸준히 확보하여 누적된 충분한 트레이닝 자료만 있다면 정확도를 보완할 수 있을 것이다. 즉, 해당 기법이 실제 효율적인 하천 관리를 위해 활용되기 위해서는 더 많은 이미지 자료와 추가적인 라벨링 작업이 동반되어야 한다. 이를 위해 하천 관리가 필요한 특정한 하천 구간을 한정하여 드론, CCTV 등 주기적 모니터링을 통해 고해상도 이미지 자료를 확보하고 대상 지역만을 한정하여 이미지 분류를 수행한다면 분석 정확도 및 정밀도 향상에 기여할 수 있을 것이다. 또한 단순 RGB 이미지의 보정을 통해 정확도를 향상시킨 결과로 미루어 보아 이미지 보정 방법에 대한 추가적인 연구 수행도 이루어진다면 효율적인 하천 관리를 위해 필요한 하천 공간의 정보를 얻는 수단으로 활용 가능할 것이라 판단된다.

## 감사의 글

본 연구는 과학기술정보통신부 한국건설기술연구원 연구운영비지원(주요사업)사업으로 수행되었습니다(과제번호 20220175-001, 기후위기 대응 물문제 해결형 이슈 발굴 및 미래선도 기술 개발).

본 결과물은 환경부의 재원으로 한국환경산업기술원의 물관리연구사업의 지원을 받아 연구되었습니다.(1615012820)

## References

- Jo, W., Lim, Y., and Park, K. 2019. Deep learning based Land Cover Classification Using Convolutional Neural Network: a case study of Korea. *Journal of the Korean Geographical Society* 54(1): 1-16. (in Korean)
- Kang, W., Choe, H., Jang, E., Ko, D., Kang, J., and Yeo, H. 2021a. Determination of Stream Reach for River Environment Assessment System Using Satellite Image. *Ecology and Resilient Infrastructure* 8(4): 179-193. (in Korean)
- Kang, W., Jang, E.K., Yang, C.Y., and Julien, P.Y. 2021b. Geospatial analysis and model development for specific degradation in South Korea using model tree data mining. *Catena*, 200, 105142.
- Kang, W., Lee, K., and Jang, E.K. 2022a. Evaluation and Validation of Estimated Sediment Yield and Transport Model Developed with Model Tree Technique. *Applied Sciences* 12(3), 1119.
- Kang, W., Lee, K., and Kim, J. 2022b. Prediction of Suspended Sediment Concentration Based on the Turbidity-Concentration Relationship Determined via Underwater Image Analysis. *Applied Sciences* 12(12), 6125.
- Kang, W., Yang, C.Y., Lee, J., and Julien, P.Y. 2019. Sediment yield for ungauged watersheds in South Korea. *KSCE Journal of Civil Engineering* 23(12): 5109-5120.
- Kim, H. and Yeom, J. 2012. A Study on Object-Based Image Analysis Methods for Land Cover Classification in Agricultural Areas. *The Korean Association of Geographic Information Studies* 15(4): 26-41. (in Korean)
- Lee, G. and Choi, Y. 2014. Land Cover Classification of Nakdong River Basin using Object-Based Image Analysis Methods. *Journal of The Korean Cadastre Information Association* 16(3): 3-18. (in Korean)
- Lee, H., Ru, J., and Yu, Y. 2010. Extracting High Quality Thematic Information by Using High-Resolution Satellite Imagery. *Journal of Korean Society for Geospatial Information Science* 18(1): 73-81. (in Korean)
- Woo, H. 2017. Assessment of Definitions and Models of River Restoration based on the Functions, Services, and Values of River Ecosystem. *Ecology and Resilient Infrastructure* 4(3): 123-129. (in Korean)