

## Forest Change Detection Service Based on Artificial Intelligence Learning Data

Hankun Chung<sup>†</sup> · Jong-in Kim<sup>††</sup> · Sun Young Ko<sup>†</sup> · Seunggi Chai<sup>†††</sup> · Youngtae Shin<sup>††††</sup>

### ABSTRACT

Since the era of the 4th industrial revolution has been ripe, the use of artificial intelligence(AI) based on massive data is beginning to be actively applied in various fields. However, as the process of analyzing forest species is carried out manually, many errors are occurring. Therefore, in this paper, about 60,000 pieces of AI learning data were automatically analyzed for pine, larch, conifer, and broadleaf trees of aerial photographs and pseudo images in the metropolitan area, and an AI model was developed to distinguish tree species. Through this, it is expected to increase in work efficiency by using the tree species division image as basic data when producing forest change detection and forest field topics.

Keywords : Artificial Intelligence, Learning Data, Forest Tree Species, Forest Change Detection, Aerial Photographs

## 인공지능 학습용 데이터 기반의 산림변화탐지 서비스

정 한 균<sup>†</sup> · 김 종 인<sup>††</sup> · 고 선 영<sup>†</sup> · 채 승 기<sup>†††</sup> · 신 용 태<sup>††††</sup>

### 요 약

4차 산업혁명 시대가 무르익으면서 방대한 데이터를 기반으로 한 인공지능(AI, Artificial Intelligence)의 활용이 전 산업 분야로 확대 중이다. 그러나 산림 수종을 분석하는 분야는 지금까지 인공지능의 활용이 미진하여 여전히 수작업으로 분석하고 있고 다수의 오류가 발생하고 있다. 본 연구에서는 수도권의 항공사진과 모사 이미지 등을 이용하여 소나무, 낙엽송, 침엽수, 활엽수 등 산림 수종을 분석하기 위한 인공지능 학습용 데이터 약 60,000장을 구축하였고 수종 구분 AI 모델도 함께 개발하였다. 이러한 연구는 우리나라의 산림 변화를 사전에 예측하여 변화에 신속한 대응이 가능하고 산림 주제도 제작 시 필요한 수종 분할 이미지를 기초자료로 활용함으로써 업무 생산성을 높일 것으로 기대한다.

키워드 : 인공지능, 학습용 데이터, 산림 수종, 산림변화탐지, 항공사진

### 1. 서 론

2020년과 2021년에 정부가 발표한 한국판 디지털 뉴딜은 디지털 전환을 통해 신산업을 육성하고 새로운 성장 동력을 확보하려는 국가발전 전략이다. 디지털 뉴딜에서 인공지능 학습용 데이터의 플랫폼을 구축하는 것은 디지털 뉴딜의 대표이자 핵심과제이다. 정부는 2017년부터 인공지능 학습용 데이터를 지속 구축하여 민간에 개방 중이며 현재까지 21종의 데이터를 약 460만 건가량 구축하였다. 이 중 국토환경

분야에서 수도권, 충청도, 강원도 지역의 환경변화 탐지와 산림 자동 분할 기술 개발을 위한 데이터로 이미지 인공지능 학습용 데이터 4종이 구축되었다[1].

우리 국토는 산림이 약 63%를 차지하여 우리 산림은 국가 산업 발전의 터전으로 인식된다. 이에 우리 산림은 지속 가능한 보전이 요구되고 이를 위한 이용 기술을 필요로 한다. 우리나라 전 산업 분야에서 인공지능 등 다양한 최신 기술이 확대 적용되고 있지만, 산림 수종 분류 작업은 이러한 기술의 적용이 미흡하다. 여전히 사람의 눈을 이용하는 육안 판독 등 수작업에 의존하고 있어 작업자 휴면 오류가 많고 실시간으로 데이터를 현행화하는 것도 어려운 실정이다.

이에 본 논문에서는 산림 수종 분석 서비스 선진화를 위해 고품질 산림 정보 학습용 이미지 데이터 확보를 통한 자동 분류체계 방안 및 알고리즘을 개발하였다. 이를 통해 산림 변화를 탐지하고 산림 분야 주제도 제작 시 효율적으로 활용될 수 있는 인공지능 기반의 산림변화탐지 서비스 방안을 제시하였다.

\* 이 논문은 2021년 한국정보처리학회 ACK 2021에서 “인공지능 학습용 데이터 기반의 산림수종 분석 모델”의 제목으로 발표된 논문을 확장한 것임.

† 준 희 원 : 송실대학교 IT정책경영학과 박사과정

†† 비 회 원 : 송실대학교 IT정책경영학과 박사과정

††† 비 회 원 : (주)울포랜드 전략사업 그룹장

†††† 종신회원 : 송실대학교 컴퓨터학부 교수

Manuscript Received : December 31, 2021

First Revision : February 9, 2022

Accepted : February 11, 2022

\* Corresponding Author : Hankun Chung(hankunch@naver.com)

## 2. 산림 수종 학습용 데이터 개요

### 2.1 산림 수종 학습용 데이터 설계

산림 수종 학습용 데이터는 국토지리정보원에서 제공하는 해상도 25cm의 항공 영상을 이용하여 총 60,892장의 데이터를 다음 Table 1과 같이 구축하였다[2]. 또한, 모사 이미지는 Pseudo image 생성 알고리즘을 이용하여 범용적 활용 불가 해상도의 영상을 모사하였다. 사용자 애플리케이션에 적합한 해상도의 영상을 제공하기 위해 해상도 5m 위성영상 (RapidEye)을 참조하여 항공 영상(25cm)을 5m 해상도로 구축하였다. RapidEye 위성은 2008년 the Space Agency of German Aerospace Center(DLR)에 의해 발사된 중고 해상도 지구관측위성으로 고도는 약 630km이며 총 5개의 동일 위성으로 구성되어 동시에 관측된다. 제공하고 있는 영

Table 1. Number of Constructed Forest Species Learning Data

|                   | Class                    | Number | Unit | Total  |
|-------------------|--------------------------|--------|------|--------|
| Fine annotation   | Aerial Image 512 * 512   | 18,506 | Page | 22,977 |
|                   | Aerial Image 1024 * 1024 | 4,301  | Page |        |
|                   | Copy Image 512 * 512     | 170    | Page |        |
| Coarse annotation | Aerial Image 512 * 512   | 37,585 | Page | 37,915 |
|                   | Copy Image 512 * 512     | 330    | Page |        |

Table 2. Classification of Aerial Image for Forest Species Learning Data

| Code | Class      | R   | G   | B   | Color | Gray Scale |
|------|------------|-----|-----|-----|-------|------------|
| N01  | Pine       | 165 | 145 | 104 |       | 110        |
| N02  | Larch      | 191 | 150 | 119 |       | 120        |
| N03  | Conifer    | 129 | 94  | 41  |       | 130        |
| N04  | Broadleaf  | 198 | 235 | 97  |       | 140        |
| N08  | N/A        | 0   | 0   | 0   |       | 0          |
| N09  | Non-forest | 204 | 204 | 204 |       | 190        |

상은 Red, Green, Blue, Red Edge, near IR의 5개 밴드 영상이다. 수종은 다음 Table 2와 같이 총 6개 구분하였다, 소나무, 낙엽송, 기타 침엽수, 활엽수 4개의 수종에 ‘판독 불가’와 ‘비 산림’ 2개의 분류를 추가하였다. 소나무, 낙엽송, 침엽수, 활엽수 4종의 산림 수종에 대한 항목은 산림 훼손 모니터링을 위한 주요 항목으로, 학습용 데이터 구축 및 AI 적용 시 임상도 현행화 업무에 활용이 쉽다.

모사 이미지는 범용적 활용 불가 해상도의 위성영상을 모사하여 사용자 애플리케이션에 적합한 해상도의 영상 제공이 필요하다. 기존 항공 이미지는 특정 해상도의 영상만이 범용적인 활용이 가능하며, 비공개 해상도의 영상을 필요로 하는 사용자 애플리케이션은 서비스에 적합한 해상도의 영상 활용이 불가하여 공개된 해상도의 영상을 사용하게 되는데 이로 인해 서비스 품질 저하가 발생할 수 있다.

이러한 문제를 해결하기 위해 Fig. 1과 같이 종전의 범용적 활용 가능 해상도의 영상을 딥러닝 기반의 영상 생성 네트워크를 활용하여 pseudo 영상을 생성하고, 생성된 pseudo 영상은 기존의 범용적 활용 가능 해상도 영상과 함께 제공하여 사용자 애플리케이션에 적합한 해상도의 영상으로 활용할 수 있도록 구축하였다(항공 영상과 같은 Red, Green, Blue 3개 밴드).

메타데이터 구성 항목은 다음 Table 4와 같다. 이미지 식별자는 원시 이미지 파일명을 의미하며 너비와 높이는 512x512로서 학습을 위한 데이터의 크기를 나타낸다. 이미지 좌표계

Table 3. Classification of Forest Species Learning Data Copy Image

| Code | Class      | R   | G   | B   | Color | Gray Scale |
|------|------------|-----|-----|-----|-------|------------|
| N04  | Broadleaf  | 198 | 235 | 97  |       | 140        |
| N05  | Conifer    | 33  | 102 | 139 |       | 150        |
| N08  | N/A        | 0   | 0   | 0   |       | 0          |
| N09  | Non-forest | 204 | 204 | 204 |       | 190        |



Fig. 1. Pseudo Image

Table 4. Construction of Metadata of Forest Species Learning Data

| No   | Item           |                         | Type   | Default |
|------|----------------|-------------------------|--------|---------|
|      | Name           | Context                 |        |         |
| 1    | Image          | Raw Image Data          |        |         |
| 1-1  | img_id         | Raw Image Identifier    | String | Y       |
| 1-2  | img_width      | Raw Image Width         | Number | Y       |
| 1-3  | img_height     | Raw Image Height        | Number | Y       |
| 1-4  | img_type       | Raw Image Type          | String | Y       |
| 1-5  | img_coordinate | Raw Image Coordinate    | String | Y       |
| 1-6  | coordinates    | Raw Image UL Coordinate | String | Y       |
| 1-7  | img_resolution | Raw Image Resolution    | Number |         |
| 1-8  | img_provided   | Raw Image PROVORG       | String | Y       |
| 1-9  | img_time       | Raw Image Shooting Time | String | Y       |
| 1-10 | img_winter     | Raw Image Winter Check  | String | Y       |
| 2    | Annotations    | Annotation Information  |        |         |
| 2-1  | ann_id         | Annotation Identifier   | String | Y       |
| 2-2  | ann_type       | Annotation Type         | String | Y       |
| 2-3  | ann_file_type  | Annotation File Type    | String | Y       |
| 3    | Provided       | PROVORG Information     |        |         |
| 3-1  | provided_nm    | PROVORG Name            | String | Y       |

코드는 국제 좌표계 정의인 EPSG(European Petroleum Survey Group) 고유 명칭이며 EPSG:5186은 GRS80 타원체의 한국 중부원점을 나타낸다. 즉 X축으로 200,000m, Y축으로 600,000m씩 이동시킨 좌표계를 의미한다.

## 2.2 산림 수종 학습용 데이터 구축

산림 수종 학습용 데이터의 획득부터 검증 단계까지 다음 Fig. 2와 같이 3단계의 구축 절차를 수립하였고 상세 작업 공정에 대한 표준 절차를 마련하여 고품질의 학습용 데이터를 구축하였다[3].

산림 내 수목을 구획하는 6종의 어노테이션 클래스 분류 기준은 다음 Table 5와 같다[4].

- ① 소나무(N01): 소나무와 곱슬을 구획한다. 촬영 경사각에 의해 기울어진 구획은 영상에 보이는 그대로 적용 한다.
- ② 낙엽송(N02): 낙엽송을 구획하며 촬영 경사각에 의해 기울어진 구획은 영상에 보이는 그대로 구획한다. 최대한 여름 영상을 이용하는데 이는 겨울 영상에서는 낙엽 송 구분이 활엽수와 비슷하기 때문이다.
- ③ 기타 침엽수(N03): 잣나무, 편백, 삼나무 등 기타 침엽 수를 구획하고 촬영 경사각에 의해 기울어진 구획은 영상에 보이는 그대로 적용한다.
- ④ 활엽수(N04): 활엽수를 구획하고 수관 축 중심이 아닌 수관 경계를 기준으로 구획하며 그림자는 포함하지 않는다.
- ⑤ 판독 불가(N08): 수종 판독이 불가능한 지역으로서 혼효림, 조림지, 그림자 등을 포함한다.
- ⑥ 비 산림(N09): 산림 지역이 아닌 곳으로 과수원, 수채, 벌채지, 주거지 등을 포함한다.

Fine annotation은 객체의 경계를 분류하는 어노테이션이며 QGIS(Quantum GIS)를 이용하여 구축하였다. 다음 Table 6은 4종 클래스에 대한 어노테이션 예시이다.

Coarse annotation은 객체 내부 분류를 위한 어노테이션이며 클라우드 기반 시스템을 통해 작업하였다.

## 3. 산림 수종 데이터 활용 인공지능 모델 개발

### 3.1 인공지능 학습모델 선정

산림 수종 인공지능 모델을 개발하기 위해 먼저 각각의 인공지능 모델을 평가한 후 산림 수종 학습용 데이터에 최적화

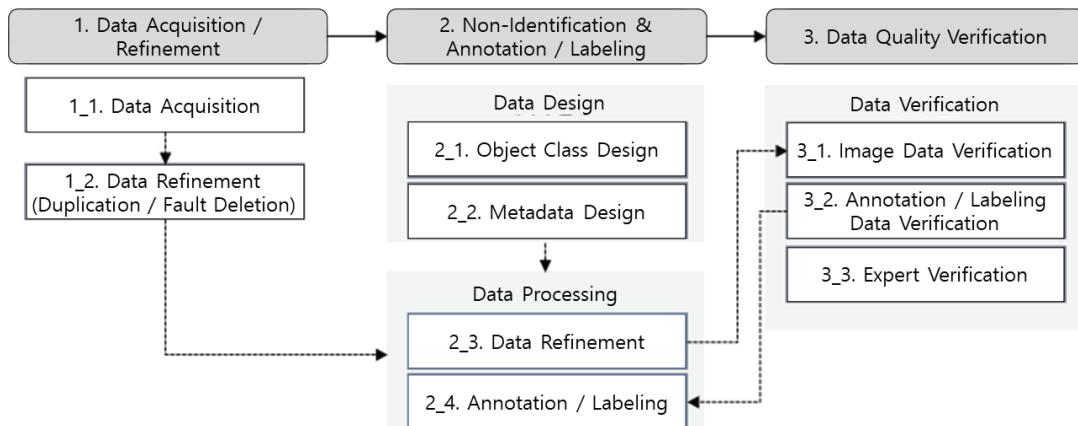


Fig. 2. Construction Procedure of Learning Data

Table 5. Data Annotation Classification Standard for Forest Species Learning Data

| Code | Class       | Annotation Classification |  |  |
|------|-------------|---------------------------|--|--|
| N01  | Pine        |                           |  |  |
| N02  | Larch       |                           |  |  |
| N03  | Conifer     |                           |  |  |
| N04  | Broadleaf   |                           |  |  |
| N08  | N/A         |                           |  |  |
| N09  | Non- forest |                           |  |  |

Table 6. Fine Annotation Data Result (Example)

| Aerial Image (25cm)                       | Category Classification | Annotation Result |           |
|---|-------------------------|-------------------|-----------|
|   |                         |                   |           |
| Creation of Learning Image Set Categories |                         |                   |           |
|   |                         |                   |           |
| Pine                                      | Larch                   | Conifer           | Broadleaf |

\*Create Numerous Features (Polygons) within a Single Image

된 모델을 선정하였다. 보통의 semantic segmentation과 비교해서 color, texture 등의 lower level features를 이용하기 위한 연구의 축과 클래스별 분포 차이에 따라 야기되는 성능 편향성을 해결하는 연구의 축으로 진행하였다.

Semantic segmentation[5-8]은 통상 dense prediction

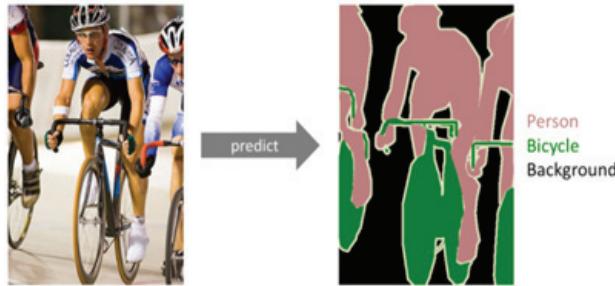


Fig. 3. Semantic Segmentation

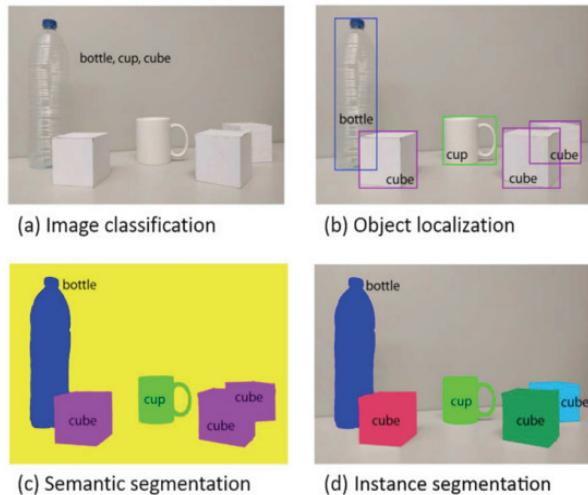


Fig. 4. Difference Between Semantic and Instance segmentation

이라고 하는데 이미지의 물체를 픽셀 레벨에 해당하는 클래스로 매칭하는 방법이다.

물체 인식 방법은 다음 Fig. 4와 같이 나눠진다. semantic segmentation과 instance segmentation은 분류 유형이 class인지 instance인지에 따른 차이점이 있다.

본 연구에서는 overall accuracy로 성능을 비교하여 SOTA (State-of-the-Art) semantic segmentation 모델들을 다수 평가하였다. 그 결과 인공지능 학습용 산림 수종 데이터에 가장 최적화되었다고 평가된 모델인 DeepLabV3+를 선정하였다.

다음 Fig. 5는 vanilla unet network을 활용한 모델의 개괄적인 학습 및 출력 데이터의 흐름을 나타낸다. 입력 이미지는 unet network 구조에 따라 초반 부분 레이어에서 down sampling 되고, 후반 부분 레이어에 skip connection이 추가되면서 up sampling 된다. 이후 정해진 loss 함수에서 GT와 prediction 간의 차이를 구하고, back propagation되면서 학습을 진행한다[9,10]. Coarse annotation, fine annotation 데이터를 순차적으로 학습시켜 모델의 성능을 극대화할 수 있는 학습 방법을 도출하여 적용하였다. 모델의 출력은  $512 \times 512$  크기에 항공 영상 클래스 수 채널의 array이며, 후처리를 거쳐 annotation 색상표에서 정의한 gray scale의 이미지와 RGB 이미지를 출력하는 구조이다.

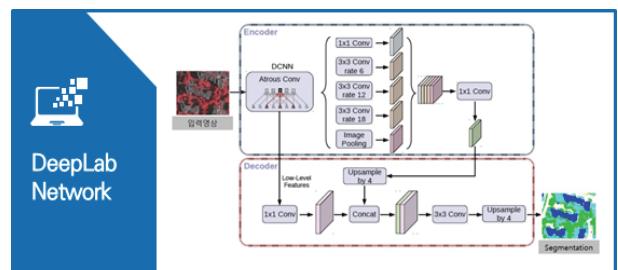


Fig. 6. Satellite Image Semantic Segmentation Based on DeepLab Network

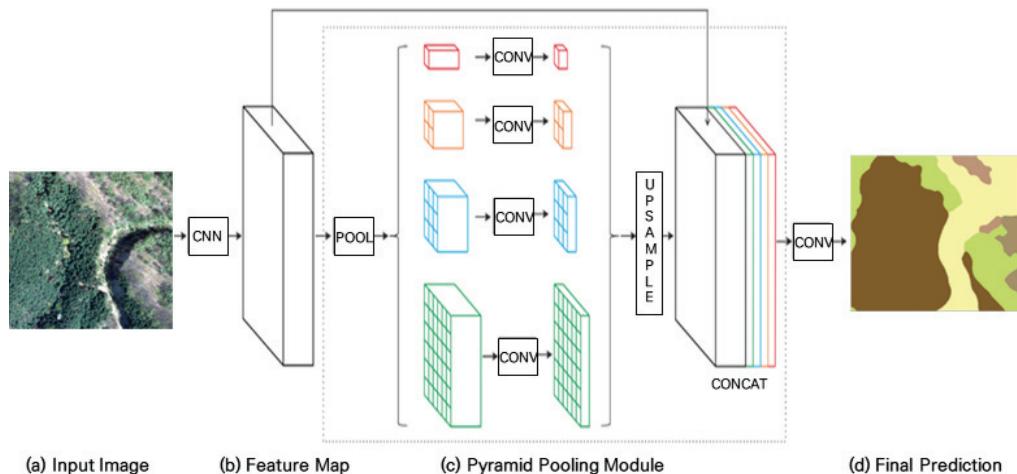


Fig. 5. DeepLabV3+Structure

Table 7. Learning Model Comparison

| Model       | Specification   |
|-------------|---|
| DeepLab V3+ | <ul style="list-style-type: none"> <li>- DeepLab, initiated in 2015, Use Atrous Spatial Pyramid Pooling to Enhance Accuracy</li> <li>- Later, it Developed to DeepLab v2, v3. In 2018, DeepLab v3+ Showed High Performance of 89% mIOU in PASCAL VOC 2012 Data Set.</li> </ul>  |
| U-net       | <ul style="list-style-type: none"> <li>- U-Net with U-type encoder-decoder structure is announced, and more sophisticated prediction is possible through gradual restoration of information on loss due to spatial dimension reduction in encoder structure through skip-connection in decoder structure.</li> </ul>                              |
| HRNet-OCR   | <ul style="list-style-type: none"> <li>- HRNet-OCR, which showed high performance in 2020 semantic segmentation, achieved 85.1% mIOU at Cityscapes test data set.</li> <li>- Rather than learning every attention mask of fixed scales, HRNet-OCR selected hierarchical method that learns relative attention mask of adjacent scales.</li> </ul> |
| SegNet      | <ul style="list-style-type: none"> <li>- Decoder network that is related to encoder network according to the final pixel classification layer exists.</li> <li>- Encoder network consists 13 convolutional layers.</li> </ul>   |

#### 4. 인공지능 학습용 데이터 활용 응용서비스

##### 4.1 딥랩 네트워크를 활용한 항공 위성 이미지 Semantic Segmentation

Semantic segmentation은 이미지 속의 물체들을 분석하여 의미 있는 단위로 나누는 기술이다. 2015년에 최초의 pixel-wise end-to-end 예측 모델인 fully convolutional network(FCN)가 발표되면서 semantic segmentation 성능을 대폭 높였지만, up-sampling을 통해 복원하는 방식을 사용하여 정밀한 결과를 얻기 어려웠다. 2017년 발표된 딥랩은 Atrous Spatial Pyramid Pooling 기술을 이용하여 정밀도를 한층 높였다. 이후 발전된 딥랩 v3+는 PASCAL VOC 2012 데이터 세트에서 약 89% mIOU로 현재 semantic segmentation에서 성능이 가장 높은 것으로 평가되고 있다.

본 논문에서는 기존의 Atrous Spatial Pyramid Pooling을 동일하게 사용하였으며, 파라미터 수를 줄여주는 depth-wise separable convolution을 적용한 Xception encoder와 segmentation의 정교함을 살리기 위해 bilinear up-sampling 후 concat 하는 과정을 추가한 U-Net 스타일 decoder를 사용하여 파라미터 수 대비 성능을 극대화하여서, 정밀도가

높은 딥랩 네트워크를 활용한 항공 위성 이미지 semantic segmentation 개발하였다.

##### 4.2 알고리즘 품질검증 결과

본 연구에서는 인공지능 알고리즘을 학습데이터로 훈련 시 목표 성능 달성을 여부를 확인하는 유효성을 토대로 다음 Fig. 7 DeepLabV3+ Resnet backbone 학습모델을 통한 알고리즘 성능 검증을 수행하였다[11-13].

Backbone 모델별 각 지표성능을 위한 학습데이터 구성은 학습, 검증, 테스트를 8:1:1 비율로 구성하였다. 항공 영상은 512×512, 25cm로 총 3,533장(학습 3133, 검증 200, 테스

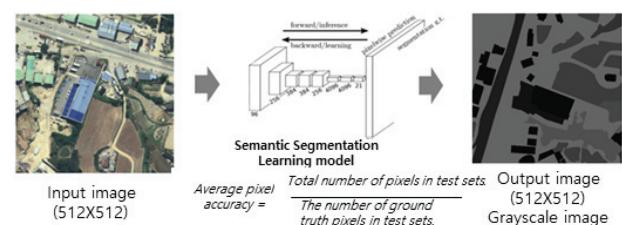


Fig. 7. Effectiveness Test Environment Diagram

Table 8. Performance of Backbone Model

(Unit : %)

| Indicators | Resnet | Mobilenet | Xception | Efficientnet | Ensemble |
|------------|--------|-----------|----------|--------------|----------|
| Accuracy   | 92.484 | 93.857    | 92.627   | 89.186       | 93.957   |
| mIoU       | 66.077 | 75.39     | 72.275   | 62.91        | 74.835   |
| fwIoU      | 87.964 | 89.569    | 87.696   | 82.464       | 89.799   |

Table 9. Accuracy Performance of Backbone Model

(Unit : %)

| Items      | Resnet | Mobilenet | Xception | Efficientnet | Ensemble |
|------------|--------|-----------|----------|--------------|----------|
| Pine       | 86.242 | 86.109    | 84.632   | 72.326       | 86.576   |
| Larch      | 85.093 | 87.098    | 85.064   | 75.276       | 87.243   |
| Confier    | 87.012 | 89.151    | 87.341   | 81.111       | 90.112   |
| Broadleaf  | 95.433 | 96.798    | 95.675   | 95.001       | 96.566   |
| Non-forest | 94.983 | 95.738    | 95.122   | 91.99        | 96.469   |

트 200)으로 진행하였으며, 다음 Table 8과 같은 결과가 도출되었다.

Accuracy는 Ensemble, mIoU는 Mobilenet, fwIoU에서는 Ensemble 모델이 가장 높은 성능을 보이며, 특히 단일 backbone 모델 중 Mobilenet이 Ensemble Model에 준하는 성능을 보였다.

Table 9와 같이 Backbone model 별 4개 클래스 accuracy 성능은 거의 모든 항목에서 Ensemble 모델이 가장 높은 성능을 보였고, 활엽수는 근소하게 Mobilenet이 가장 높은 성능을 보였다. 특히 단일 backbone 모델 중 Mobilenet이 Ensemble 모델에 준하는 성능을 보였다. 활엽수, 비 산림이 다른 클래스에 비해 높은 성능을 보였다. 그 원인은 다른 클래스에 비해 상대적으로 texture, color feature 등의 구분이 쉬웠던 결과이다.

#### 4.3 활용 응용서비스 개발

본 논문에서 개발한 알고리즘을 기반으로 1) 사용자의 항공 위성 이미지를 이용한 Semantic Segmentation 결과의 시각화 2) 사용자의 전 시기, 후 시기 이미지를 이용한 변화 탐지 서비스 3) 항공 위성 및 AI 실행 결과 이미지를 이용한 면적측량 서비스 등 3가지 유형의 활용 응용서비스를 개발하였다. 사용자 시계열 이미지의 변화탐지 서비스는 Fig. 8에서



Fig. 8. Change Detection Service of User Time Series Image



Fig. 9. Guide Service for Forest Species of Changed Area

와 같이 전후 시기의 산림변화탐지 서비스를 시계열로 분석해 볼 수 있다.

또한, 산림 변화 지에 대한 조립수종 안내 서비스는 Fig. 9와 같이 산림 지역 내에 나대지, 도로, 건물 등 산림 변화가 의심되는 비 산림 항목에 대한 판별할 수 있으며, 사용자가 비 산림 지역의 조림 및 최적 수목 선정을 목적으로 사용할 수 있도록 판별 결과 이미지 파일로 다운로드도 가능하다.

## 5. 결론 및 향후연구

우리나라의 산림이 차지하는 면적은 2015년 기준 6,335,000 ha로 우리 국토의 약 63.2 %를 차지하고 있다. 산림 면적 비율은 OECD 국가 중 4위로서 산림 면적이 매우 높은 수준이다. 최근에도 산지 이용 수요가 높고 수요 형태도 다양하며 무분별한 산지 전용 행위는 여전히 많이 발생하는 편이다.

따라서 본 연구는 산림 수종에 대한 알고리즘 개발과 학습용 데이터 구축을 통해 인공지능을 이용한 산지 훼손 의심 지역 자동 추출 서비스를 개발하였다. 또한, 사용자의 전시기, 후 시기 이미지를 이용한 변화탐지 서비스를 개발하여 산림 변화지역을 분류하고 해당 지역에 맞는 조립수종을 안내하는 서비스를 개발하였다.

또한, 재난 발생 후 피해 발생 규모, 피해 금액 산정 및 피해 지역 모니터링 시 참조할 수 있는 기초자료로 활용할 수 있다. 지자체 불법 무허가 건축물 등 변화탐지에 활용하면 하천 및 소하천, 공유수면에서 발생 되는 무단 점유 등 불법행위에 대해 영상판독 및 현장 조사 업무를 AI 데이터 세트를 활용한 분석이 가능하다.

본 논문은 수도권, 충청도, 강원도 지역의 제한된 산림 수종 학습용 데이터를 바탕으로 연구되었다. 향후 전국 단위의 산림 수종 학습용 데이터를 구축하여 국가 전체적인 산림 변화에 적극적으로 대응할 수 있는 다양한 서비스연구가 필요하다.

## References

- [1] AI Hub [Internet], <http://www.aihub.or.kr>
- [2] Creation Guideline for Artificial Intelligence Learning Data Set, NIA, 2021.
- [3] Quality Management Guideline for Artificial Intelligence Learning Data v1.0, NIA, 2021.
- [4] 국립산림과학원, “디지털 항공영상을 이용한 대축적 임상도 제작 및 캡신방법,” 2012.
- [5] D. Lobo Torres, R. Queiroz Feitosa, P. Nigri Happ, L. Elena Cué La Rosa, J. Marcato Junior, J. Martins, P. Olá Bressan, W. N. Gonçalves, and V. Liesenberg, “Applying fully convolutional architectures for semantic segmentation of a single tree species in urban environment on high resolution UAV optical imagery,” *Sensors*, Vol.20, No.2, pp.563, 2020.
- [6] V. Andersson, Semantic Segmentation: Using Convolutional Neural Networks and Sparse Dictionaries. 2017.

- [7] J. Long, E. Shelhamer, and T. Darrell, "Fully convolutional networks for semantic segmentation," In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.3431-3440, 2015.
- [8] A. Zlateski, R. Jaroensri, P. Sharma, and F. Durand, "On the importance of label quality for semantic segmentation," In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.1479-1487, 2018.
- [9] L. C. Chen, Y. Zhu, G. Papandreou, F. Schroff, and H. Adam, "Encoder-decoder with atrous separable convolution for semantic image segmentation," *ECCV*, 2018.
- [10] L. C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, and A. L. Yuille, "DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.40, No.4, pp.834-848, 2018.
- [11] J. P. Papa, A.X. FalcāO, V. H. C. De Albuquerque, and J. M. R. Tavares, "Efficient supervised optimum-path forest classification for large datasets," *Pattern Recognit*, Vol.45, No.1, pp.512-520, 2012.
- [12] L. G. Hafemann, L. S. Oliveira, and P. Cavalin, "Forest Species Recognition using Deep Convolutional Neural Networks," In *2014 22nd International Conference on Pattern Recognition*, pp.1103-1107, 2014.
- [13] P. P. de Bem, O. A. de Carvalho Junior, R. Fontes Guimarães, and R. A. Trancoso Gomes, "Change detection of deforestation in the Brazilian Amazon using landsat data and convolutional neural networks," *Remote Sensing*, Vol.12, No.6, pp.901, 2020.



### 김종인

<https://orcid.org/0000-0001-9130-0110>  
e-mail : jikim0110@naver.com  
2005년 아주대학교 경영학과(학사)  
2010년 연세대학교 산업정보경영학과(석사)  
2020년 ~ 현 재 승실대학교 IT정책경영학과  
박사과정

2019년 ~ 현 재 한국금거래소 디지털에셋 대표이사  
관심분야: Blockchain, Digital Asset & NFT



### 고선영

<https://orcid.org/0000-0002-7730-1835>  
e-mail : fallhasgone@gmail.com  
1999년 성신여자대학교 전산학과(학사)  
2017년 충남대학교 특허법무학과(석사)  
2020년 ~ 현 재 승실대학교 IT정책경영학과  
박사과정

2008년 ~ 현 재 문화체육관광부 기획조정실 주무관  
관심분야: Metaverse, Digital Copyright, Data Science



### 채승기

<https://orcid.org/0000-0002-7996-0228>  
e-mail : sgchai@hanmail.net  
1995년 연세대학교 전산학과(학사)  
1997년 연세대학교 전산학과(석사)  
2014년 ~ 현 재 (주)올포랜드 전략사업  
그룹장

관심분야: Artificial Intelligence, Geospatial Business  
Model, BigData, Metaverse



### 정한균

<https://orcid.org/0000-0003-0731-2069>  
e-mail : hankunch@naver.com  
1991년 목포대학교 전산통계학과(학사)  
1994년 목포대학교 전산통계학과(석사)  
2018년 연세대학교 산업정보경영전공(석사)  
2020년 ~ 현 재 승실대학교 IT정책경영학과  
박사과정

2021년 ~ 현 재 행정안전부 정보자원관리과장

관심분야: AI 딥러닝, 비대면 서비스, 메타버스 콘텐츠



### 신용태

<https://orcid.org/0000-0002-1199-1845>  
e-mail : shin@ssu.ac.kr  
1985년 한양대학교 산업공학과(학사)  
1990년 Univ. of Iowa, 컴퓨터학과(석사)  
1994년 Univ. of Iowa, 컴퓨터학과(박사)  
1995년 ~ 현 재 승실대학교 컴퓨터학부  
교수

관심분야: 정보보호, 인터넷 프로토콜, IoT, 가상융합기술