

# 딥러닝 기반 3D LiDAR 데이터를 활용한 도시수목 인스턴스 분할 및 형상 정보 추출 연구

정인혜\*

대진대학교 스마트모빌리티 조교수

## A Study on Deep Learning-Based Instance Segmentation and Feature Extraction of Urban Trees Using 3D LiDAR Data

In-Hye Jung\*

Professor, Division of Smart Mobility, Daejin University

**요약** 기존 인력 중심 수목 조사는 막대한 시간과 비용이 소모되며 조사자의 주관에 따른 오차가 발생하는 한계가 있었다. 이를 해결하기 위해 본 연구에서는 고해상도 3차원 모바일 라이다 포인트 클라우드 데이터와 딥러닝 아키텍처를 융합하여 도심 객체 분류부터 개별 수목 분리 및 수종 판별에 이르는 전 과정을 자동화하는 방안을 제안한다. 특히 포인트 클라우드의 계층적 특징 학습에 탁월한 PointNet++ 모델을 도입하였다. 연구 방법으로는 먼저 의미론적 분할을 통해 건물 및 인공 구조물로부터 수목 영역을 격리한 후, 인스턴스 분할을 적용하여 개별 수목 개체에 고유 ID를 부여하였다. 이후 지면으로부터 1.2~1.3m 높이의 단면 데이터를 추출하여 DBSCAN 클러스터링으로 줄기 포인트를 정제하고, 흉고직경 및 수고를 자동으로 산출하였다. 경기도 인근 약 6km 구간의 데이터를 바탕으로 실증 실험을 수행한 결과, 총 1,252개의 가로수 객체에 대한 수목 특성 정보 데이터베이스를 구축하였다. 지상 실측 데이터와 비교 검증한 결과, 전체 자동 분류 수목 중 64.7%의 개체가 오차율 15% 이내의 높은 정밀도로 수렴함을 확인하였다. 연구의 결과는 전통적인 산림 자원 조사의 효율성을 향상시키고 도시수목 자원관리시스템 구축에 기여할 것이다.

**주제어** : 라이다, 포인트클라우드, 포인트넷, 딥러닝, 흉고직경

**Abstract** Traditional labor-intensive tree surveys involve substantial time and cost and may produce inconsistent results due to surveyors' subjective judgments. To overcome these limitations, this study integrates high-resolution 3D mobile LiDAR (Light Detection and Ranging) point cloud data with deep learning to automate urban object classification, individual tree isolation, and species identification. The PointNet++ model was applied to learn hierarchical spatial features directly from point cloud data. Semantic segmentation was first used to distinguish trees from buildings and other artificial structures, followed by instance segmentation to assign a unique ID to each tree. Cross-sectional data at 1.2-1.3 m above ground were then extracted, and stem points were refined using DBSCAN clustering to calculate diameter at breast height and tree height automatically. Experiments conducted along a 6 km corridor in Suwon, Gyeonggi-do, produced a structural attribute database for 1,252 street trees. Validation against field measurements showed that 64.7% of the classified trees had an error rate below 15%. These findings demonstrate the potential of the proposed method to improve forest inventory efficiency and support intelligent urban tree resource management.

**Key Words** : LiDAR, Point LiDAR, PointNet++, deep learning, DBH

\*교신저자 : 정인혜(ihjung@daejin.ac.kr)

접수일 2026년 06월 16일

수정일 2026년 08월 12일

심사완료일 2026년 08월 19일

## 1. 서론

도시수목은 도시 생태계의 핵심 구성요소로서 탄소흡수, 미세기후 조절, 열섬현상 완화, 대기질 개선, 경관 향상 등 다양한 환경적 기능을 수행한다. 특히 기후변화 대응과 탄소중립 정책이 강조되면서 도시수목의 생육 상태와 공간적 분포를 정량적으로 파악하고, 이를 기반으로 체계적인 도시녹지 관리 방안을 수립하는 것이 중요해지고 있다. 그러나 기존의 도시수목 조사는 조사자가 현장에서 수목의 위치, 수종, 흉고직경, 수고, 수관폭 등을 직접 측정하는 방식에 의존하는 경우가 많아 조사 범위, 소요 시간, 인력 투입 측면에서 한계가 있다.

최근에는 이러한 한계를 보완하기 위해 LiDAR 기반 3차원 공간정보 데이터의 활용 가능성이 주목받고 있다. 라이다라는 대상 지역의 지형, 시설물, 식생 구조를 고밀도 포인트클라우드 형태로 취득할 수 있어 수목의 입체적 구조와 생육 특성을 분석하는 데 유용하다. 특히 도시지역과 같이 건물, 도로, 보행자, 차량, 가로시설물, 수목 등이 복합적으로 존재하는 공간에서는 2차원 영상만으로 수목 구조를 정밀하게 파악하기 어렵기 때문에 3차원 라이다 데이터의 활용 가치가 크다.

그러나 LiDAR 포인트클라우드 데이터는 데이터 용량이 크고, 점군의 밀도와 구조가 불균일하며, 도시공간 내 다양한 객체가 혼재되어 있어 수목 객체만을 자동으로 분리하고 특징을 추출하는 데 기술적 어려움이 존재한다. 기존의 수작업 분류 방식이나 규칙 기반 알고리즘은 분석자의 경험과 판단에 의존하는 경향이 있으며, 대규모 데이터 처리 시 시간과 비용이 크게 증가한다. 또한 복잡한 도시환경에서는 수목 간 중첩, 시설물에 의한 가림, 스캔 방향에 따른 누락, 반사 오차 등이 발생할 수 있어 분석 결과의 일관성과 신뢰성을 확보하는 것이 중요하다.

이에 본 연구는 LiDAR 포인트클라우드 데이터를 활용하여 도시수목을 자동으로 분류하고, 개별 수목의 주요 생육 특성을 추출할 수 있는 딥러닝 기반 분석 방법론을 제안하고자 한다. 특히 3D 포인트클라우드 데이터 처리에 적합한 PointNet++ 모델을 적용하여 도시공간 내 수목 객체를 분류하고, 분류된 수목을 대상으로 흉고직경, 수고, 수관폭 등 특징값을 자동 산출하는 절차를 설계하였다. 또한 현장 실측 데이터와 고정 시

설물 검증 실험을 통해 LiDAR 기반 분석 결과의 신뢰성을 평가하였다.

본 연구의 목적은 첫째, 차량 탑재 모바일 LiDAR로 취득한 복잡한 도시공간 포인트클라우드에서 의미론적 분할, 개별 수목 인스턴스 분할 및 수종 분류를 하나의 처리 과정으로 통합하였다. 둘째, 분류된 개별 수목 객체를 흉고직경, 수고 및 수관폭 산출과 직접 연계하여 도시수목 관리용 객체 단위 데이터베이스를 구축하였다. 셋째, 수관 중첩과 시설물 가림이 존재하는 도시 가로수 환경을 대상으로 개별 수목 분리 가능성을 검토하였다. 넷째, 수종 분류 정확도와 현장 실측값 기반 형상 정보 추출 정확도를 구분하여 제안 방법의 적용 가능성을 검증하였다.

## 2. 선행연구

### 2.1 도시 수목 조사 및 관리의 현황과 한계

전통적인 수목 정보 수집은 국가산림자원조사와 같이 전문가가 현장에서 수고, 흉고직경 등을 직접 측정하는 인력 기반 조사에 의존해 왔다. 그러나 이러한 방식은 조사 범위가 넓어질수록 시간과 비용이 기하급수적으로 증가하며, 조사자의 주관에 따른 오차 가능성을 배제하기 어렵다는 한계가 있다. 최근 항공 라이다를 활용한 수목 정보 추출 연구가 진행되고 있으나, 이는 주로 수목 간격이 일정하거나 밀도가 낮은 지역에 국한되어 있다. 따라서 수목이 밀집되어 있거나 비정형적으로 배치된 국내 도심 환경의 특성을 반영하여 고해상도 3D 데이터를 기반으로 특징을 자동 추출하는 방법론이 요구된다.

### 2.2 LiDAR 포인트클라우드와 딥러닝기반 분석기술

LiDAR 기술은 대상물에 레이저를 조사하여 반사된 신호를 통해 초고용량의 3차원 포인트 클라우드 데이터를 생성한다. 이러한 포인트 데이터는 형상이 복잡한 도심 수목의 정확한 기하학적 정보를 포함하고 있지만, 비정형적인 데이터 구조로 인해 기존의 규칙 기반 알고리즘으로는 개별 개체를 정밀하게 분류하는 데 한계가 있다. 최근에는 3차원 공간상의 복잡한 패턴과 구조적 관계를 효과적으로 학습할 수 있는 PointNet++와 같

은 딥러닝 아키텍처가 제안되었다. PointNet++는 샘플링 및 그룹핑(Grouping) 계층을 통해 국부적 특징(Local Feature)을 계층적으로 학습하며, 특히 포인트 밀도가 균일하지 않은 도심 환경에서도 강건한 성능을 발휘한다.

## 2.3 수목 객체 분리 및 특징 추출 알고리즘

LiDAR 기반 도시수목 분석을 위해서는 단순히 점군 데이터를 확보하는 것만으로는 충분하지 않으며, 데이터 정제, 세분화, 라벨링, 모델 학습, 수목 객체 분리, 특징 산출의 연속적 절차가 필요하다. 본 연구의 분석 체계는 원천 LiDAR 포인트 클라우드 데이터를 전처리한 후 학습 데이터셋을 구축하고, 딥러닝 모델을 이용하여 수목을 분류한 뒤, 개별 수목 단위로 흉고직경, 수고, 수관폭 등을 산출하는 구조로 설계된다. 본 연구에서는 수목 분류 및 특징 분석을 위한 목표 공정을 데이터 세분화, 수목 분류, 수목 객체 분리, 수종 분류, 특성 분석의 단계로 제시하며, LiDAR 데이터를 활용한 자동화 공정은 세 단계의 의미적 분석 과정을 거친다.

〈Table 1〉 Object Separation and Extraction Algorithm

| Category              | Description                                                                                                                             |
|-----------------------|-----------------------------------------------------------------------------------------------------------------------------------------|
| Semantic Segmentation | Separating tree regions from background elements such as buildings, ground, and vehicles within the entire point 라이다                    |
| Instance Segmentation | Identifying individual tree instances within the segmented tree point clusters and isolating them as independent objects                |
| Classification        | Classifying specific tree species (e.g., ginkgo, pine, and zelkova) by learning the morphological features of the isolated tree objects |

학습 데이터셋 구축은 딥러닝 모델 성능을 좌우하는 핵심 과정이다. 라이다 원시데이터는 Track, Area, Part 단위로 정제 및 세분화되고, 건물, 자동차, 바닥, 전봇대, 관목, 나무 등 객체별 세그멘테이션을 거쳐 라벨링 데이터로 변환된다. 이후 모델 학습이 가능한 어노테이션 데이터로 전처리되며, 수목 객체에 대해서는 수종 분류 및 개별 수목 특징 분석이 가능하도록 별도의 데이터셋이 구축한다.

## 3. 연구방법

### 3.1 연구프로세스

본 연구의 전체 분석 흐름은 원천 라이다 포인트클라우드 데이터를 입력자료로 사용하고, 이를 모델 학습이 가능한 형태로 전처리한 후, 딥러닝 모델을 통해 수목 객체를 분류하는 방식이다. 이후 분류된 수목 객체를 개별 단위로 분리하고, 산정 알고리즘을 적용하여 DBH, 수고, 수관폭 등 도시수목 관리에 필요한 기초 속성값을 산출하였다. 보고서에서도 수목 분석 목표 공정을 데이터 세분화, 수목 분류, 수목 객체 분리, 수종 분류, 특성 분석 단계로 제시하고 있으며, 각 단계는 Semantic Segmentation, Instance Segmentation, Classification 및 알고리즘 기반 특징 산출 과정으로 구성된다.

| Category                         | Detailed Implementation Process                               |
|----------------------------------|---------------------------------------------------------------|
| Preliminary Research             | Review of background theories and literature                  |
|                                  | Model survey → Testing → Comparative analysis → Selection     |
|                                  | Dataset survey → Structural analysis                          |
| System Design                    | Process design for tree classification and feature extraction |
|                                  | Overall system architecture design                            |
| System Development               | Modular role and functional design                            |
| Data Engineering & Preprocessing | Training dataset construction planning                        |
|                                  | Raw data refinement → Data segmentation                       |
|                                  | Source data processing → Segmentation → Labeling              |
|                                  | Annotation data generation                                    |
| Model Training & Validation      | Dataset training/tuning → Performance evaluation & revision   |
|                                  | Project development completion                                |

[Fig. 1] Detailed Research Process

### 3.2 연구 분석방법론

본 연구는 라이다 포인트클라우드 데이터를 활용하여 도시수목을 자동으로 분류하고, 개별 수목의 주요 생육 특성을 추출하기 위한 딥러닝 기반 분석 방법론을 적용하였다. 연구 절차는 ① 데이터셋 구축 및 전처리 ② 수목 특징 정보 추출 알고리즘 ③ 모델 학습 및 검증 순서로 구성하였다.

#### 3.2.1 데이터셋 구축 및 전처리

LHSegDataset의 클래스는 건물(Building), 자동차(Car), 바닥(Ground), 전봇대/신호등(Pole), 관목(Shrub), 나무(Tree), 비분류(Unknown)의 7개이며, 도심 포인트클라우드 전체의 77.25%를 차지한다. LHTreeDataset은 현장 조사를 통해 확인된 수종—느티나무(Zelkova, 246개), 은행나무(Ginkgo, 367개), 소나무(Pinus, 195개), 플라타너스(Platanus, 202개), 중국단풍(Acer, 93개) 등 10개 주요 수종을 포함하여 총 1,251개의 수목 개체로 구성된다.


〈Table 2〉 Dataset Development Process

| Dataset Stage    | Description                                                                                                                                                                                                                   |
|------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Data Acquisition | Collection of 6 km LiDAR data in Suwon, Gyeonggi-do via vehicle-mounted sensors (MMS)                                                                                                                                         |
| Data Refining    | <ul style="list-style-type: none"> <li>Sorting, classification, and editing by track, area, and part</li> <li>Data cleaning (removal of noise and unidentifiable points)</li> </ul>                                           |
|                  | <ul style="list-style-type: none"> <li>Segmentation: Differentiating points by specific classes</li> <li>Data structuring for dataset configuration</li> </ul>                                                                |
| Data Processing  | Automated generation via segmentation and manual text input                                                                                                                                                                   |
| Test             | <ul style="list-style-type: none"> <li>Quality inspection of class attributes and annotations</li> <li>Test training and performance metric evaluation</li> <li>Preprocessing and final annotation data generation</li> </ul> |

#### 3.2.2 수목 특징 정보 추출 알고리즘

본 플로우차트는 라이다 기반 도시수목 특징 추출 프로그램의 모듈별 처리 흐름을 제시한 것이다. 프로그램은 원시 포인트클라우드 데이터의 입력을 시작으로 데이

터 정제, 세분화, 라벨링, 데이터 로딩 및 모델 학습 단계를 수행하며, 학습된 모델을 기반으로 수목 객체를 자동 분류한다. 이후 개별 수목 단위의 객체 분리, 수종 분류, DBH·수고·수관폭 산출 및 결과 시각화가 순차적으로 이루어진다. 이러한 구조는 데이터 전처리부터 분석 결과 산출까지의 전 과정을 자동화함으로써 기존 수작업 기반 도시수목 조사 방식의 시간적·공간적 한계를 보완하고, 도시녹지 관리 및 수목 DB 구축에 활용 가능한 정량 정보를 제공한다.



〔Fig. 2〕 Processing pipeline of the automated tree feature extraction program

〈Table 3〉 Tree Feature Extraction Algorithm

| Category                 | Extracted Parameter | Description                                                                                           |
|--------------------------|---------------------|-------------------------------------------------------------------------------------------------------|
| Spatial Information      | Center Coordinates  | Central coordinates of each individual tree object                                                    |
| Morphological Attributes | TH                  | Calculated based on the vertical distance between the lowest and highest points of the tree point 라이다 |
|                          | DBH                 | Calculated based on the stem cross-section info at 1.3 m above the ground level                       |
|                          | CW                  | Calculated based on the horizontal spatial extent of the tree crown point 라이다                         |
|                          | Crown Height        | Vertical extent (thickness) of the isolated tree crown region                                         |
| Data Storage             | CSV                 | Saving extracted feature values per tree in a database-compatible format                              |

### 3.2.2.1 흉고직경 추출

DBH는 지상 1.3 m 높이 주변의 포인트를 추출한 후, DBSCAN 클러스터링으로 노이즈를 제거하고 RANSAC (Random Sample Consensus) 원형 피팅 알고리즘을 적용하여 산출한다. 차량 탑재 라이다의 특성상 수목 후면 데이터가 부족한 경우, 관측 각도(Observed Angle)를 계산하여 보정 계수를 적용한다: 관측 각도 270° 이상이면 1.05배, 180° 이상이면 1.10배, 그 미만이면 1.15배를 기본 보정값(1.2배)에 추가 적용한다. 최종 DBH는 9cm ~ 100cm의 현실적 범위로 제한하며, 신뢰도 점수(각도 커버리지 40%, 인라이어 비율 20%, 반경 편차 20%, 균일성 20%)를 산출한다.

더불어 1.1 m ~ 1.5 m 구간을 0.1 m 간격으로 다중 측정하여 이상치 제거 후 평균하는 mDBH(Multi-level DBH)도 함께 산출한다.

### 3.2.2.2 수고 추출

수고는 포인트의 Z값 분포에서 상위 1% 점들의 평균(수목 상단부)과 하위 0.2% 점들의 평균(지면 높이)의 차이로 계산하며, 참조 지면 높이를 사용함으로써 일관성을 확보한다.


### 3.2.2.3 수관폭 추출

수관부를 5개 층으로 구분하여 각 층의 포인트에 대해 Convex Hull을 적용하고, 상위 3개 층의 수관폭 평균값을 최종 수관폭으로 결정한다. 층별 분석으로 수직 구조를 반영하고 이상치를 자동 제거한다.

## 3.2.3 모델 학습 및 검증

### 3.2.3.1 모델 학습 과정

본 연구에서는 라이다 포인트클라우드 데이터를 활용한 도시수목 분류 및 특징 추출 모델을 구축하기 위해 라벨링된 데이터를 학습 가능한 형태로 전처리하고, 이를 훈련 데이터와 검증 데이터로 구분하여 학습을 수행하였다. 모델 학습 과정에서는 입력 데이터의 특성과 분석 목적에 적합하도록 학습률, 배치 크기, 에포크 수, 손실 함수 등 주요 하이퍼파라미터를 설정하였으며, 반복적인 학습과 검증을 통해 모델의 예측 성능을 개선하였다. 또한 과적합을 방지하기 위해 정규화, 드롭아웃, 조기 종료 등의 기법을 적용하여 도시수목 분류 및 특징 추출에 적합한 안정적인 딥러닝 모델을 도출하고자 하였다.



[Fig. 3] Model training and validation process

학습 과정은 데이터 배치 입력, 순전파, 손실 계산, 역전파, 가중치 갱신, 과적합 방지의 순서로 수행하였다. 손실 함수는 예측값과 실제 라벨 간의 차이를 계산하는데 활용되었으며, 정규화, 드롭아웃, 조기 종료 등의 방법을 적용하여 모델의 일반화 성능을 확보하고자 하였다. 모델 검증은 주기적으로 검증 데이터셋을 활용하여 수행하였으며, 성능 결과에 따라 하이퍼파라미터를 조정하고 필요한 경우 모델 구조를 수정하였다.

### 3.2.3.2 검증 및 성능평가

본 연구에서는 학습된 모델의 일반화 성능을 확인하기 위해 검증 데이터셋을 활용하여 주기적으로 성능을 평가하였다. 모델이 학습 데이터뿐만 아니라 새로운 LiDAR 포인트클라우드 데이터에서도 수목 객체를 정확하게 분류하는지를 확인하였으며, 이를 위해 Precision, IoU, Accuracy 등의 성능지표를 적용하였다. 검증 결과를 바탕으로 모델의 분류 정확도와 세그멘테이션 성능을 분석하고, 필요에 따라 학습률, 배치 크기 등 하이퍼파라미터를 조정하거나 모델 구조를 보완하여 최종 성능을 개선하였다.

〈Table 4〉 Evaluation Metrics and Verification Methods for Model Performance

| Category            | Verification Details & Methods                                                                                                                                                                                                           |
|---------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Model Validation    | <ul style="list-style-type: none"> <li>Evaluating model performance periodically using the validation dataset</li> <li>Verifying the model's capability to generalize and predict unseen (new) data based on learned features</li> </ul> |
| Performance Metrics | <ul style="list-style-type: none"> <li>Assessing validation results quantitatively using Precision, Intersection over Union (IoU), and Accuracy</li> <li>Measuring how accurately the model classifies target object classes</li> </ul>  |
| Model Tuning        | <ul style="list-style-type: none"> <li>Adjusting hyperparameters based on evaluation feedback</li> <li>Modifying the network architecture if necessary to optimize and improve overall model performance</li> </ul>                      |

## 4. 연구결과

### 4.1 모델 성능

의미론적 세그멘테이션 모델은 약 1,500 에포크 학습을 거쳐 IoU 96.03%, mIoU 86.54%를 달성하였으며, 이는 목표치를 상회하고 세계 최고 수준과 대등하거나 이를 능가하는 결과이다. 수종 분류 모델은 1,667 에포크 학습 후 최고 Instance Accuracy 98.61%(Train), 최고 Test Accuracy 96.96%, 평균 클래스 정확도 96.96%를 달성하였다.

〈Table 5〉 Evaluation Metrics and Quantitative Results

| Process               | Performance Metric | Unit | Result | Metric Description & Measurement Method                                                                         |
|-----------------------|--------------------|------|--------|-----------------------------------------------------------------------------------------------------------------|
| Semantic Segmentation | IoU                | %    | 96.03% | A metric evaluating segmentation performance, calculated as the ratio of the predicted area to the Ground Truth |
|                       | mIoU               | %    | 86.54% | The average of IoU values computed across multiple object classes                                               |
| Classification        | Accuracy           | %    | 96.96% | Overall classification accuracy, calculated as: Number of Correct Predictions/Total Number of Predictions       |

```
Model - INFO - Epoch 324 (442/1000):
Model - INFO - Train Instance Accuracy: 0.998625
Model - INFO - Test Instance Accuracy: 0.965278, Mean Class Accuracy: 0.919681
Model - INFO - Per-class Accuracy:
Model - INFO - acer: 95.83%
Model - INFO - Chionanthus: 100.00%
Model - INFO - Diospyros: 62.56%
Model - INFO - Cinkgo: 94.84%
Model - INFO - Kplne: 75.00%
Model - INFO - Maple: 100.00%
Model - INFO - Palustris: 100.00%
Model - INFO - Pinus: 100.00%
Model - INFO - Platanus: 100.00%
Model - INFO - Zelkova: 92.31%
Model - INFO - Best Instance Accuracy: 0.979167, Best Class Accuracy: 0.953791
Model - INFO - Epoch 325 (443/1000):
Model - INFO - Train Instance Accuracy: 0.982292
Model - INFO - Save model...
Model - INFO - Saving at log/classification/pointnet2_cls_msg/checkpoints/best_model_class_acc_0.9696.pth
Model - INFO - Test Instance Accuracy: 0.979167, Mean Class Accuracy: 0.969609
Model - INFO - Per-class Accuracy:
```

〔Fig. 4〕 semantic segmentation

```
2024-12-15 08:19:02,111 - Model - *** Epoch 1 (119/500) ***
2024-12-15 08:19:02,111 - Model - INFO - Testing on dev 2
2024-12-15 08:19:02,111 - Model - INFO - Learning rate: 0.01200
2024-12-15 08:19:02,111 - Model - INFO - BN momentum updated to: 0.025000
2024-12-15 08:46:17,213 - Model - INFO - Training mean loss: 0.805984
2024-12-15 08:46:17,213 - Model - INFO - Training accuracy: 0.97012
2024-12-15 08:46:17,213 - Model - INFO - True class accuracy: 0.999099
2024-12-15 08:46:27,582 - Model - INFO - ----- EP01 dev EVALUATION -----
2024-12-15 08:47:03,885 - Model - INFO - eval mean loss: 0.163
2024-12-15 08:47:03,885 - Model - INFO - eval point avg class iou: 0.800
2024-12-15 08:47:03,886 - Model - INFO - eval point accuracy: 0.972
2024-12-15 08:47:03,886 - Model - INFO - ----- dev per class -----
2024-12-15 08:47:03,886 - Model - INFO - class Building iou: 0.959
2024-12-15 08:47:03,886 - Model - INFO - class Car iou: 0.832
2024-12-15 08:47:03,886 - Model - INFO - class Crowd iou: 0.978
2024-12-15 08:47:03,886 - Model - INFO - class Pole iou: 0.488
2024-12-15 08:47:03,886 - Model - INFO - class Shrub iou: 0.627
2024-12-15 08:47:03,886 - Model - INFO - class Tree iou: 0.960
2024-12-15 08:47:03,886 - Model - INFO - class Tree iou: 0.960
2024-12-15 08:47:03,886 - Model - INFO - Free class iou: 0.800311
2024-12-15 08:47:03,886 - Model - INFO - eval mean loss: 0.163
2024-12-15 08:47:03,886 - Model - INFO - eval accuracy: 0.972
2024-12-15 08:47:03,886 - Model - INFO - Saving best model (Tree iou) at log/sem_seg/pointnet2_sem_seg/checkpoints/best_model.pth
2024-12-15 08:47:03,886 - Model - INFO - Saving best model (Tree performance) at models/checkpoints/pointnet2_sem_seg/best_model_TreeIOU_0.960311.pth
2024-12-15 08:47:03,886 - Model - INFO - Best Tree iou: 0.960
2024-12-15 08:47:03,886 - Model - INFO - ----- Processing time: 3445.62 minutes -----
```


〔Fig. 5〕 Tree Classification

개별 수목 객체의 분리 성능을 정량적으로 평가하기 위해 Precision, Recall 및 인스턴스 단위 F1-score를 산출하였다. 평가 결과, 전체 예측 객체 960개 가운데 920개가 실제 수목 객체와 올바르게 대응되어 Precision은 95.83%로 나타났다. 또한 실제 수목 객체 1,000개 가운데 920개를 정확하게 탐지하여 Recall은 92.00%로 분석되었다. Precision과 Recall의 조화평균인 인스턴스 단위 F1-score는 93.88%로 산출되었다.


## 4.2 수종별 분류 정확도

〈Table 6〉 Data Quantity and Classification Accuracy by Tree Class

| Tree Class (Species)  | Class Name  | Quantity | Distribution Rate (%) | Final Accuracy (%) |
|-----------------------|-------------|----------|-----------------------|--------------------|
| Acer buergerianum     | Acer        | 93       | 7.43%                 | 95.83%             |
| Chionanthus retusus   | Chionanthus | 45       | 3.60%                 | 100%               |
| Diospyros kaki        | Diospyros   | 12       | 0.96%                 | 37.5%              |
| Ginkgo biloba         | Ginkgo      | 367      | 29.34%                | 99.24%             |
| Pinus koraiensis      | Kpine       | 10       | 0.80%                 | 75.0%              |
| Acer palmatum         | Maple       | 36       | 2.88%                 | 66.67%             |
| Quercus palustris     | Palustris   | 45       | 3.60%                 | 100.0%             |
| Pinus densiflora      | Pinus       | 195      | 15.59%                | 100.0%             |
| Platanus occidentalis | Platanus    | 202      | 16.15%                | 100.0%             |
| Zelkova serrata       | Zelkova     | 246      | 19.66%                | 91.21%             |



[Fig. 6] Training and Test Accuracy Curves



[Fig. 7] Final Class-wise Accuracy

수종별 데이터는 은행나무 367개에 비해 감나무 12개, 잣나무 10개로 크게 불균형하였다. 감나무 37.5%, 단풍나무 66.67%, 잣나무 75.0%의 상대적으로 낮은 정확도는 수종별 형태적 유사성뿐만 아니라 부족한 학습 표본의 영향을 받은 것으로 판단된다. 반면 일부 수종에서 나타난 100% 정확도는 실제 일반화 성능이라기보다 소수의 테스트 표본으로 인해 과대평가되었을 가능성이 있다. 따라서 전체 정확도와 함께 수종별 테스트 표본 수, Precision, Recall, F1-score 및 혼동행렬을 함께 검토할 필요가 있다.

## 5. 결론

본 연구는 라이다 포인트클라우드 데이터를 활용하여 도시수목의 분류와 생육 특성 추출을 자동화하기 위한 딥러닝 기반 분석 방법론을 제안하였다. 기존 도시수목 조사는 현장 인력에 의한 수작업 조사에 의존하는 경우가 많아 조사 범위, 소요 시간, 결과의 일관성 측면에서 한계가 있었다. 이에 본 연구에서는 대용량 3차원 점군 데이터를 기반으로 수목 객체를 자동 분류하고, 개별 수목의 흉고직경, 수고, 수관폭 등 주요 특징을 산출할 수 있는 분석 체계를 구축하였다.

연구 결과, PointNet++ 기반 딥러닝 모델은 도시공간의 복잡한 포인트클라우드 데이터에서 수목 객체를 분류하고 특징을 추출하는 데 적용 가능성이 있음을 확인하였다. PointNet++는 다양한 크기와 구조를 가진 점군 데이터를 직접 처리할 수 있으며, 점들의 공간적 관계와 지역적 특징을 반영할 수 있어 도시수목과 같은 비정형 객체 분석에 적합한 구조를 가진다. 특히 본 연구에서는 데이터 세분화, 수목 분류, 수목 객체 분리, 수종 분류, 특성 분석으로 이어지는 단계적 분석 공정을 구성하여 원시 라이다 데이터로부터 도시수목 관리에 필요한 정량 정보를 생성하였다.

또한 본 연구에서는 도시수목 분석을 위한 학습 데이터셋을 구축하고, 수목 분류 및 수종 분류가 가능한 데이터 구조를 마련하였다. 라이다 원시데이터는 정제, 세분화, 세그멘테이션, 라벨링, 어노테이션 생성 과정을 거쳐 학습 가능한 형태로 변환되었으며, 이를 기반으로 수목 객체의 자동 분류와 특징 분석을 수행하였다. 이러

한 과정은 기존의 규칙 기반 또는 수작업 기반 분석 방식이 갖는 시간적·인력적 한계를 보완하고, 대규모 도시 녹지 데이터를 체계적으로 구축할 수 있는 가능성을 보여준다.

검증 결과에서도 라이다 기반 자동 분석의 실용 가능성을 확인할 수 있었다. 고정 시설물을 대상으로 현장 실측값과 라이다 산출값을 비교한 결과, 반사 등으로 인한 일부 이상값을 보정한 후 측정 오차가 약  $\pm 5\%$  이내로 나타났으며, 이는 라이다 데이터가 도시공간 객체의 형상 및 규모를 비교적 정밀하게 반영할 수 있음을 의미한다. 또한 수목의 1.3m 높이 둘레 실측값을 기반으로 산출 흉고직경과 비교함으로써 수목 특징 분석 결과의 신뢰성을 검토하였다.

향후 연구에서는 다양한 지역과 수종을 대상으로 학습 데이터 라이브러리를 확대하고, 라이다 측정 기준과 데이터 품질관리 절차를 표준화할 필요가 있다. 또한 계절별 수목 형태 변화, 수관 중첩, 가로시설물에 의한 가림 현상 등을 고려한 보정 알고리즘을 개발한다면 도시수목 분석의 정확도와 현장 적용성이 더욱 향상될 수 있다. 나아가 본 연구에서 제안한 분석 체계를 도시 디지털트윈 플랫폼과 연계할 경우, 도시수목의 생육 상태 모니터링, 유지관리 우선순위 도출, 탄소흡수량 산정, 도시녹지 정책 수립을 지원하는 데이터 기반 의사결정 도구로 확장될 수 있을 것이다.

## REFERENCES

- [1] I.H.Choi, S.K.Nam, S.Y.Kim, and D.G.Lee, "Automatic Extraction of Tree Information in Forest Areas Using Local Maxima Based on Aerial LiDAR," *Korean Journal of Remote Sensing*, Vol.39, No.5, pp. 1155-1164, 2023.
- [2] S.I.Park, S.G.Jeong, and H.J.Lee, "Quality Analysis of Individual Tree Detection in Natural Forest by Forest Type Based on LiDAR Technology," *Journal of the Korean Society for Geospatial Information Science*, Vol.32, No.2, pp. 31-40, 2024.
- [3] B.J.Ko, "Applicability and Application Methods of Terrestrial LiDAR for Forest Survey," Master's Dissertation, Jeonbuk National University Graduate School, Jeonbuk, Korea, 2021.
- [4] A.Diab, R.Kashef, and A.Shaker, "Deep Learning for LiDAR Point Classification in Remote Sensing," *Sensors*, Vol.22, No.20, p.7868, 2022.
- [5] W.Wu, Z.Qi, and L.Fuxin, "PointConv: Deep Convolutional Networks on 3D Point 라이다," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Long Beach, CA, USA, 2019, pp. 9621-9630.
- [6] C.R.Qi, H.Su, K.Mo, and L.J.Guibas, "PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, HI, USA, 2017, pp. 77-85.
- [7] C.R.Qi, L.Yi, H.Su, and L.J.Guibas, "PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space," in *Advances in Neural Information Processing Systems*, Vol.30, pp. 5099-5108, 2017.
- [8] M.A.Lefsky, W.B.Cohen, G.G.Parker, and D.J.Harding, "Lidar Remote Sensing for Ecosystem Studies," *BioScience*, Vol.52, No.1, pp. 19-30, 2002.
- [9] Z.Zhen, L.J.Quackenbush, and L.Zhang, "Trends in Automatic Individual Tree Crown Detection and Delineation—Evolution of LiDAR Data," *Remote Sensing*, Vol.8, No.4, p.333, 2016.
- [10] W.Li, Q.Guo, M.K.Jakubowski, and M.Kelly, "A New Method for Segmenting Individual Trees from the Lidar Point 라이다," *Photogrammetric Engineering & Remote Sensing*, Vol.78, No.1, pp. 75-84, 2012.
- [11] B.Koch, U.Heyder, and H.Weinacker, "Detection of Individual Tree Crowns in Airborne Lidar Data," *Photogrammetric Engineering & Remote Sensing*, Vol.72, No.4, pp.357-363, 2006.
- [12] H.Kaartinen, J.Hyyppä, X.Yu, M.Vastaranta, H.Hyyppä, A.Kukko, M.Holopainen, C.Heipke, M.Hirschmugl, F.Morsdorf, E.Næsset, J.Pitkänen, S.Popescu, S.Solberg, B.M.Wolf, and J.C.Wu, "An International Comparison of Individual Tree Detection and Extraction Using Airborne Laser Scanning," *Remote Sensing*, Vol.4, No.4, pp. 950-974, 2012.
- [13] M.Dalponte and D.A.Coomes, "Tree-Centric Mapping of Forest Carbon Density from Airborne Laser Scanning and Hyperspectral Data," *Methods in Ecology and Evolution*, Vol.7, No.10, pp. 1236-1245, 2016.
- [14] B.Xiang, M.Wielgosz, T.Kontogianni, T.Peters, S.Puliti, R.Astrup, and K.Schindler, "Automated Forest Inventory: Analysis of High-Density Airborne LiDAR Point LiDARs with 3D Deep Learning," *Remote Sensing of Environment*, Vol.305, p.114078, 2024.
- [15] S.Krisanski, M.S.Taskhiri, S.G.Aracil, D.Herries, and P.Turner, "Sensor Agnostic Semantic Segmentation of Structurally Diverse and Complex Forest Point LiDARs Using Deep Learning," *Remote Sensing*, Vol.13, No.8, p.1413, 2021.

정 인 혜(In-Hye Jung)

[정회원]



- 2003년 8월 : 국민대학교 전산과 학과(공학석사)
- 2025년 9월 ~ 현재 : 대전대학교 스마트모빌리티 조교수)

〈관심분야〉

빅데이터, AI