

Laplacian Skeleton Feature를 활용한 Dual-Stream 산림 포인트 클라우드 Semantic Segmentation (Dual-Stream Semantic Segmentation of Forest Point Clouds Using Laplacian Skeleton Features)

박한음*, 정희용**, 김광일***

(Han-Eum Park, Hie Yong Jeong, Gwang-Il Kim)

요약

산림 포인트 클라우드에서 지면(ground), 목질부(wood), 잎(leaf)을 자동으로 분류하는 semantic segmentation은 바이오매스 추정, 탄소 흡수량 산정, 산림 구조 분석의 핵심 기술이다. 기존 연구들은 3D 좌표(x, y, z)만을 입력으로 사용하여 수목의 위상적(topological) 구조를 명시적으로 활용하지 못하는 한계를 가진다. 본 연구는 Laplacian-Based Contraction(LBC) 알고리즘으로부터 수목의 구조적 위치를 인코딩하는 5가지 기하학적 feature를 설계하고, 3D 공간 좌표와 기하학적 feature를 독립적인 스트림으로 처리한 뒤 GeoCrossAttn 모듈로 융합하는 Dual-Stream OA-CNNs 아키텍처를 제안한다. FOR-instanceV2 데이터셋 실험에서 제안 모델은 mIoU 90.6%를 달성하여 기존 OA-CNNs 대비 2.1%, ForestFormer3D 대비 4.4%의 성능 향상을 기록하였으며, 특히 기존 방법들이 어려움을 겪던 목질부(wood) 클래스에서 76.6%의 IoU를 달성하여 4.5%의 큰 폭의 개선을 보였다.

■ 중심어 : 포인트 클라우드 ; 라플라시안 스켈레톤 ; 시맨틱 세그멘테이션 ; 듀얼 스트림

Abstract

Semantic segmentation for automatically classifying ground, wood, and leaf in forest point clouds is a core technology for biomass estimation, carbon sequestration quantification, and forest structure analysis. Existing studies are limited in that they use only 3D coordinates (x, y, z) as input, failing to explicitly leverage the topological structure of trees. This study proposes a Dual-Stream OA-CNNs architecture that designs five geometric features encoding the structural position of trees derived from the Laplacian-Based Contraction (LBC) algorithm, processes 3D spatial coordinates and geometric features as independent streams, and fuses them via a GeoCrossAttn module. Experiments on the FOR-instanceV2 dataset demonstrate that the proposed model achieves an mIoU of 90.6%, outperforming OA-CNNs by 2.1% and ForestFormer3D by 4.4%, with a notable improvement of 4.5% in the wood class IoU, reaching 76.6%.

■ keywords : Point Cloud ; Laplacian Skeleton ; Semantic Segmentation ; Dual-Stream

I. 서론

오늘날 산림은 지구 육지 면적의 약 31%를 차지하는 핵심 자원으로, 한국은 전 국토의 62.7%

가 산림이다[1]. 산림 바이오매스는 광합성을 통해 대기 중 이산화탄소(CO₂)가 나무 유기물로 고정되는 탄소순환 과정과 직접 연결된 핵심 인자이며, 개체목 단위의 정밀 추정을 위해 수목

* 준회원, 전남대학교 인공지능융합학과 석사과정

** 종신회원, 전남대학교 인공지능융합학과 교수

*** 정회원, 전라남도 산림연구원

이 논문은 2024년도 국가유산청·국립문화유산연구원의 재원으로 지원 받아 수행된 연구결과임 (RS-2024-00397083).

사업명: 기후변화 대응 문화유산 보존관리 기술개발(P&D), 연구개발과제명: 이산화탄소 대응 식물유산 생육상태 모니터링 및 변화 예측 시스템 개발 및 실증

구조 파악이 필수적이다.

전통적 현장 조사는 흉고직경(DBH, Diameter at Breast Height)·수고 등을 측고기·직경 테이프로 수작업 측정하나, 노동집약적이고 3차원 구조 파악에 근본적 한계가 있다[2]. LiDAR 기술의 발전으로 TLS, ULS, MLS 등을 통해 수목 포인트 클라우드를 정밀하게 취득할 수 있게 되었으나, 수백만 개 이상의 포인트에서 수목 구성 요소를 자동 분류하는 semantic segmentation 기술이 필수적으로 요구된다. 기존 딥러닝 기반 방법들은 3D 좌표(x, y, z) 또는 이로부터 파생된 기하학적 특징만을 입력으로 사용하는 것이 일반적이다. 예를 들어 Bai et al.[3]는 PointNet++ 기반으로 열대림 UAV 레이저 스캐닝 데이터에서 포인트 좌표만을 입력으로 하여 leaf-wood segmentation을 수행하였으며, 본 연구에서 비교할 모델인 ForestFormer3D [4] 역시 범용성을 위해 3D 좌표만을 사용한다. 그러나 이러한 접근은 수목이 뿌리 → 줄기 → 가지 → 잎으로 이어지는 위상적(topological) 구조를 명시적으로 활용하지 못하는 한계를 가진다. 특히 줄기와 잎이 공간적으로 중첩되는 수관 내부에서는 두 클래스의 3D 좌표 분포가 유사하여 구분이 어려우며, 이는 기존 방법들의 줄기 분류 성능이 상대적으로 낮은 주요 원인으로 작용한다.

본 연구는 이러한 한계를 극복하기 위해 LBC 기반의 스켈레톤으로부터 기하학적 feature를 설계하고, 3D 좌표와 독립 스트림으로 처리·융합하는 Dual-Stream 아키텍처를 제안한다. 이를 통해 수관 내부에서 줄기와 잎이 공간적으로 중첩되는 경계 영역의 분류 정확도를 향상시켰으며, FOR-instanceV2에서 mIoU 90.6%의 SOTA 성능을 달성하고, 특히 줄기(Wood) 클래스에서 4.5%의 개선을 달성하였다.

II. 관련 연구 및 배경지식

1. LiDAR 기반 산림 조사 기술

산림 LiDAR 스캐닝은 플랫폼에 따라 세 방식으로 분류된다. TLS(Terrestrial Laser Scanning)는 밀리미터 수준의 최고 정밀도를 제공하나 고정식 특성으로 폐색(occlusion) 문제가 있다. ULS(UAV Laser Scanning)는 넓은 지역을 단시간에 측정하나 상향 스캔 특성으로 줄기 하부 점 밀도가 낮다. MLS(Mobile Laser Scanning)는 SLAM 기반으로 이동 중 연속 스캔하여 폐색 문제를 완화하며 공간적으로 균일한 점 분포를 제공한다. 본 연구는 세 방식을 모두 포괄하는 FOR-instanceV2 데이터셋을 활용하여 플랫폼에 독립적인 일반화 성능을 평가한다.

2. 수목 포인트 클라우드 분류 과제

수목 포인트 클라우드에 대한 핵심 분류 과제는 세 가지이다. 첫째, leaf-wood separation은 잎과 줄기·가지 성분을 분리하는 과제로, wood 성분이 적절히 분리되지 않을 경우 엽면적지수(LAI)가 약 3~32% 과대추정될 수 있다[5]. 둘째, 수종 분류(tree species classification)는 산림 관리·생물다양성 보전의 기반이 되는 과제이다. 셋째, 수목의 위상학적 구조 복원과 스켈레톤 추출은 바이오매스 부위별 배분과 수관 구조 분석에 직접 활용된다 [6][7]. 본 연구는 첫 번째 과제에 해당하는 지면·줄기·잎 분류에 집중하되, 세 번째 과제의 스켈레톤 정보를 feature로 활용하는 방식을 채택한다.

3. 딥러닝 기반 3D Point Cloud Segmentation

PointNet [8]은 비정형 포인트 클라우드를 직접 처리한 최초의 딥러닝 모델로, 이후 PointNet++ [9]는 계층적 구조를 도입하여 지역적 특성을 효과적으로 학습할 수 있도록 발전시켰다. Transformer 계열 연구에서는 PCT, Point Transformer V2/V3 [10] 등이 self-attention 메커니즘을 적용하여 포인트 클라우드 전반에 걸친 전역적 문맥을 포착하였다. OA-CNNs [11]는 self-attention 없이도 Transformer에 필적하는 성능을 달성하였는데, 이는 적응적 관계 컨볼루션

선(ARConv)과 적응적 집계기(Adaptive Aggregator)를 통해 다중 스케일 포인트 그리드 상에서 각 점의 수용 영역을 동적으로 조정함으로써 가능하였다. 산림 도메인에서는 ForestFormer3D 가 OneFormer3D [12] 프레임워크를 발전시켜 semantic segmentation과 instance segmentation을 통합적으로 수행하는 최신 방법으로 주목받고 있다. 한편, 수목 포인트 클라우드의 위상적 구조를 분석하는 데에는 Cao et al. [13]가 제안한 LBC 알고리즘이 널리 활용되고 있다. LBC는 포인트 클라우드에 Laplacian 기반 반복 수축을 적용하여 수목의 1차원 골격 구조와 위상 그래프를 추출하며, 이 과정에서 각 포인트와 골격 간의 기하학적 관계가 자연스럽게 정의된다. Livny et al. [14]는 유사한 수축 기반 접근으로 수목의 줄기·가지 골격 구조를 자동 복원하여 3D 수목 모델링에 활용하였으며, Meyer et al.[15]는 이 LBC를 발전시킨 CherryPicker를 통해 Semantic LBC를 도입, Wood와 branch 포인트에 의미론적으로 차별화된 가중치를 적용하여 스켈레톤 추출 과정에서 발생하는 위상학적 오류를 효과적으로 개선하였다. 그러나 이들 연구는 LBC를 스켈레톤 추출에 대한 품질 개선이나 나무의 3D 구조 복원에 활용한 반면, 추출된 골격에 대한 정보를 segmentation의 입력 feature로 직접 활용하지는 않았다. 본 연구는 LBC 알고리즘으로부터 각 포인트의 구조적 위치를 인코딩하는 5가지 기하학적 feature를 설계하고, 이를 segmentation 네트워크의 입력으로 활용하는 새로운 접근을 제안한다.

III. 제안 방법

1. Laplacian Skeleton Feature 설계

수목은 뿌리 → 줄기 → 가지 → 잎으로 이어지는 고유한 위상적 구조를 갖는다. 본 연구는 그림 1과 같이 LBC 알고리즘을 통해 나무의 포인트 클라우드에 Laplacian 기반 반복 수축을 적용하

여 수목의 1차원 골격 구조인 skeleton 포인트 클라우드와 topology graph를 추출하고, 이로부터 각 포인트의 구조적 위치를 다섯 가지 관점에서 인코딩하는 기하학적 Feature를 설계하였다. 각 feature는 수목의 특정 구조적 속성에 대응하여 서로 상보적인 정보를 제공하며, 표 1은 각 feature의 값 범위와 클래스별 특성을 요약한다.




그림 1. LBC를 통한 줄기(Wood) 포인트 클라우드로부터 Skeleton 추출

표 1. Skeleton Feature의 특성 요약

Feature	값 범위	Wood 특성	Leaf 특성
MCF	[0, 1.76]	매끄러운 원통	잎밀집/분기점
DSK	[0, ~]	골격에 근접	골격에서 이탈
ET	[0, 1]	균일 분포	말단 집중 (1에 가까움)
RGD	[0, ~]	루트 근처	루트에서 멀리
ELR	[0, ~]	굵은 줄기	얇은 말단 가지

설계한 5가지 feature는 다음과 같다. MCF(Mean Curvature Flow Magnitude)는 robust point cloud Laplacian[16] 행렬 L을 좌표 행렬 P에 적용하여 각 점의 평균 곡률 흐름 벡터의 크기를 취한 것으로, 줄기처럼 곡률 변화가 작은 영역에서는 작은 값을, 가지 분기점이나 잎 밀집 영역에서는 큰 값을 나타낸다. DSK(Distance to Skeleton Point)는 LBC로 추출한 skeleton point set S에 대해 각 원본 점에서 가장 가까운 skeleton 점까지의 유클리드 거리를 KD-tree 기반으로 계산한 값이다. ET(Edge Parameter t)는 topology graph의 각 엣지 $e = (v_s, v_e)$ 에 대해 원본 점 p의 정사영 위치를 0~1로 정규화하여, 해당 점이 가지 구간의 어느 지점에 위치하는지를 나타낸다. RGD(Root Geodesic Distance)는 Z 좌표가 최소인 노드를 루트로 선택한 뒤 다익스트라

알고리즘으로 각 노드까지의 최단 경로 거리를 계산한 것으로, 3D 직선거리가 아닌 줄기·가지를 따라 측정된 경로 거리이므로 동일 높이에 위치하더라도 분기 구조가 다른 점들을 구별할 수 있다. ELR(Edge Local Radius)은 각 엣지에 할당된 점들의 수직 거리 중앙값을 국소 반경으로 정의하며, 중앙값을 사용하여 이상치(outlier)에 의한 반경 추정 왜곡을 방지한다. 이 다섯 가지 feature는 수목의 곡률·거리·위치·깊이·두께 관점에서 상보적인 구조 정보를 제공하게 된다.

2. Dual-Stream OA-CNNs 아키텍처

서로 다른 특성의 입력데이터를 독립 스트림으로 분리 처리한 뒤 잔차적으로 융합하는 접근은 LiDAR-카메라 멀티모달 segmentation에서 그 효과가 입증된바 있다 [17][18]. 본 연구는 이러한 멀티모달 융합 전략을 3D 포인트 좌표와 skeleton feature라는 이질적 정보를 융합하는 데 적용하였다. 제안 모델은 그림 3과 같이 3D 좌표를 처리하는 Spatial Stream과 5가지 skeleton feature를 처리하는 Geo Stream으로 구성된 이중 스트림 아키텍처이다. 두 스트림을 분리한 이유는 (1) 3D 좌표와 skeleton feature는 본질적으로 서로 다른 종류의 정보를 담고 있으며, (2) 공간 좌표는 sparse convolution이 효과적이거나 skeleton feature는 5개 스칼라 간 조합적 관계 학습에 attention이 더 적합하기 때문이다.

5가지 skeleton feature는 각각 수목의 서로 다른 구조적 속성을 인코딩하지만, 줄기-잎 경계 영역에서는 단일 feature만으로 두 클래스를 구분하기 어렵다. 예를 들어 DSK(골격까지의 거리)가 작더라도 수관 내부의 잎 밀집 영역에서는 줄기와 유사한 값을 보일 수 있으므로, RGD(뿌리로부터의 깊이)나 ELR(국소 반경) 등 다른 feature와의 조합적 판단이 필요하다.

가. Geo Stream : Skeleton Feature Block

SFB Block은 이러한 feature간 상호 관계를 학

습하여 각 포인트의 구조적 위치를 하나의 임베딩으로 압축하는 역할을 하며, 그림 2와 같이 4단계로 구성된다. 먼저, 5가지 feature는 값의 범위와 분포가 서로 달라 단순 결합 시 특정 feature의 영향이 과도하게 반영될 수 있으므로, 각 feature를 별도의 MLP로 동일한 D차원 임베딩으로 변환한다. 변환된 5개의 임베딩은 $[N, 5, D]$ 형태의 토큰 시퀀스로 구성된 뒤, 2층의 4-head self-attention(FeatureCrossAttn)에 입력된다. 이 단계에서 DSK가 작고 RGD가 큰 조합은 줄기 상단, MCF가 크고 ELR이 작은 조합은 잎 밀집 영역이라는 복합적 패턴이 학습되며, 이는 개별 feature만으로는 포착할 수 없는 줄기-잎 경계의 구조적 맥락을 제공한다. 각 attention 층에는 Pre-LayerNorm과 잔차 연결(FFN 포함)을 적용하여 학습 안정성을 확보하였다. 최종적으로 attention 출력 $[N, 5, D]$ 를 $[N, 5 \times D]$ 로 펼친 후 Linear 변환으로 $[N, C]$ 의 기하 임베딩으로 압축하여 GeoStream에 전달한다. GeoStream은 기하 임베딩을 sparse voxel 구조로 변환한 뒤 2개의 SubMConv3d를 적용하여, SFB에서 학습된 구조적 정보에 인접 포인트 간 공간적 문맥을 추가로 반영한다. 이때 Spatial Stream과 별도의 인덱스 키(indice_key)를 사용하여 두 스트림이 간섭 없이 독립적으로 동작하도록 한다. 이후 Geo Encoder는 4개의 GeoDownBlock으로 구성되며, Spatial Stream과 동일한 다운샘플링 스케줄을 유지하여 각 인코더 단계에서 GeoCrossAttn 융합이 가능하도록 한다.

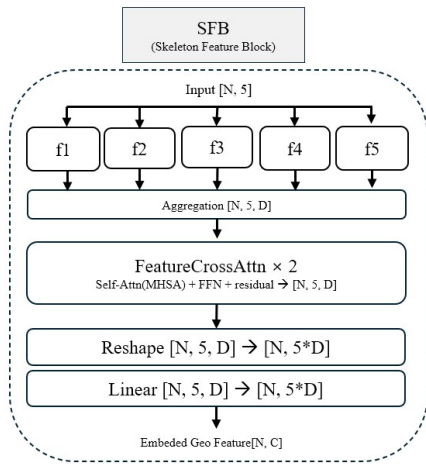


그림 2. SFB Block 다이어그램

나. Spatial Stream: OA-CNNs Backbone

입력 3D 좌표[N, 3]는 Linear 변환으로 C(=64) 차원 임베딩 후 3개의 SubMConv3d, Spatial Stem을 거친다. 4개의 인코더 단계(채널: 64→128→256→256)에서 OA-CNNs의 핵심 모듈인 ARConv(Adaptive Relation Convolution)와 Adaptive Aggregator가 적용된다. ARConv는 다중 스케일 point grid를 활용하여 각 점에 대해 적응적으로 수용 영역을 조정하며, self-attention 없이도 넓은 범위의 공간적 의존성을 모델링한다. Decoder는 4개의 UpBlock(SparseInverseConv3d + skip connection 결합)으로 구성된다.

다. GeoCrossAttn: 두 스트림 융합 모듈

Geo feature를 2층 MLP(geo_proj)로 변환 후, 학습 가능한 스칼라 α 와 곱하여 XYZ feature에 잔차적으로 더한다. α 는 0.1로 초기화되어 학습 초기에는 Geo Stream의 기여를 최소화하고, 학습이 진행됨에 따라 최적 비율을 찾게 된다. 구체적인 식은 (1)과 같다.

$$out = out_{proj}(f_{xyz} + \alpha \cdot geo_{proj}(f_{geo})) \quad (1)$$

이 잔차적 설계는 skeleton feature가 불완전하거나 노이즈가 있는 경우에도 Spatial Stream의 성능을 보존하기 위함이다. 그림 3에 나타낸 바와 같이, GeoCrossAttn은 GeoStem 단계, 4개의 Encoder 단계, Decoder 최종 출력의 총 6개 지점

에 배치되어 저해상도(전역 맥락)부터 고해상도(세밀한 경계)까지 일관된 다중 스케일 융합을 수행한다. 제안 아키텍처의 유효성을 검증하기 위해, FOR-instanceV2 데이터셋에서 ForestFormer3D, OA-CNNs 등 기존 방법들과의 정량적 성능 비교를 수행하고, 각 구성 요소의 기여를 분리 검증하기 위해 OA-CNNs 단독(baseline), skeleton feature 단순 결합(OA-CNNs + FA), 제안 Dual-Stream 구조의 세 가지 단계적 Ablation Study를 수행하였다.

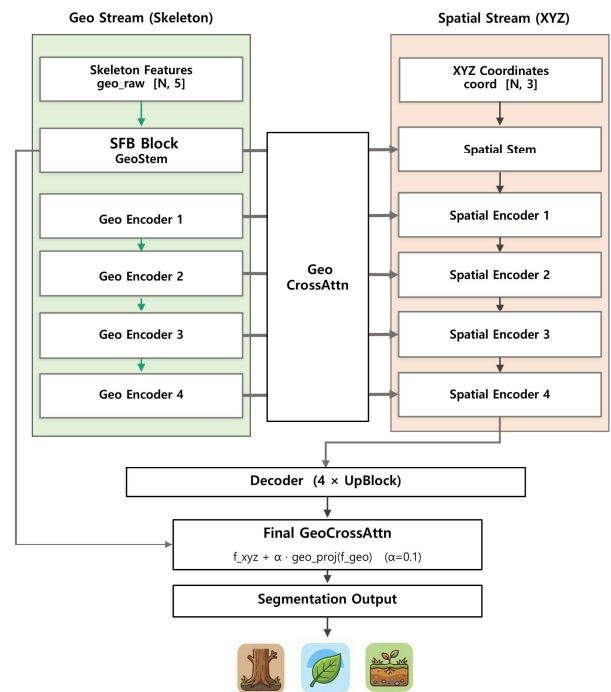


그림 3. Dual-stream 전체 아키텍처

IV. 실험 결과 및 분석

1. 데이터셋 및 전처리

FOR-instanceV2[4] 데이터셋은 산림 포인트 클라우드 segmentation 분야의 최신 벤치마크로, 기존 FOR-instance 데이터셋을 확장하여 온대 활엽림, 열대림 등 구조적 복잡성이 높은 산림 유형을 추가한 대규모 데이터셋이다. 그림 4에 나타낸 바와 같이 노르웨이, 체코, 호주, 뉴질랜드, 오스트리아, 프랑스령 기아나 등 7개국 9개 지역에서 수집

된 약 11,000그루의 개체목 점군을 포함한다. 표 2는 각 지역별 산림 유형, 데이터 수집 센서의 종류, 데이터 분할 구성을 요약한 것으로, 한대 침엽림, 온대 활엽림, 열대림 등 다양한 산림 유형과 ULS, TLS, MLS 세 가지 LiDAR 방식의 데이터를 모두 포함하며, 각 점에 지면(ground, 0), 잎(leaf, 1), 줄기(Wood, 2)의 semantic 라벨이 부여되어 있다. 여기서 줄기(Wood)는 나무의 주간(主幹, main stem)뿐 아니라 가지를 포함하는 목질부 전체를 지칭한다.

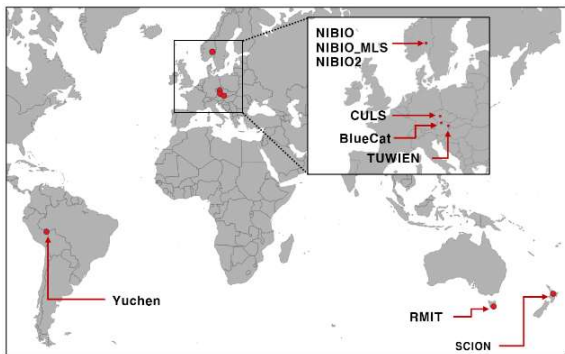


그림 4. FOR-instanceV2 데이터셋의 지역별 수집 위치 분포 (9개 지역, 7개국)

표 2. FOR-instanceV2 데이터셋 지역별 구성 요약

지역	산림유형	센서	Train/Val/Test
CULS	온대 침엽림	ULS	1 / 1 / 1
NIBIO	한대 침엽림	ULS	8 / 6 / 6
RMIT	유칼립투스	ULS	1 / 0 / 1
SCION	온대 침엽림	ULS	2 / 1 / 2
TUWIEN	온대 활엽림	ULS	1 / 0 / 1
NIBIO2	한대 침엽림	ULS	29 / 6 / 15
NIBIO_MLS	한대 침엽림	MLS	4 / 1 / 1
BlueCat	온대 활엽림	TLS	1 / 1 / 1
Yuchen	열대림	ULS	1 / 1 / 1

원본 산림 포인트 클라우드를 XY 평면 기준으로 타일링하되, 개체목의 Wood 중심점을 기준으로 할당하는 tree-atomic assignment 방식을 적용하였다. 학습에는 RTX4090 (24GB)을 사용하였으며, AdamW 옵티마이저(lr=0.001, weight_decay=0.02)와 OneCycleLR 스케줄러(cosine annealing)로 총 600 epoch 학습하였다. Voxel grid_size=0.2m,

SphereCrop으로 학습 시 포인트 수 100,000개로 제한하였으며, 테스트 데이터셋에 대하여 추론 시에는 원시 포인트를 모두 사용하였다. 포인트 데이터 증강으로 z축 랜덤 회전·스케일·플립·지터를 적용하였다.

2. 정량적 비교 결과

표 3은 FOR-instanceV2 테스트 분할에서의 클래스별 IoU와 mIoU 비교 결과를 나타낸다. 비교 대상으로는 ForestFormer3D 논문에서 보고된 ForAINetV2_R8, ForAINetV2_R16, OneFormer3D, ForestFormer3D의 결과를 사용하였다. 제안 모델은 Ground 99.5%, Wood 76.6%, Leaf 95.7%, mIoU 90.6%로 모든 클래스에서 최고 성능을 달성하였다. 특히 기존 방법들이 60~70%대에 머물렀던 줄기(Wood) 클래스에서 76.6%를 기록하여, 차순위 모델인 ForAINetV2_R16 (69.2%) 대비 7.4%, ForestFormer3D (67.7%) 대비 8.9%의 큰 폭의 개선을 보였다. 이는 수관 내부에서 3D 좌표만으로는 구분이 어려운 줄기와 잎의 경계 영역에서 skeleton feature가 구조적 위치 정보를 명시적으로 제공하고, Dual-Stream 아키텍처가 이를 효과적으로 활용한 결과로 판단된다. mIoU 기준으로는 ForestFormer3D (86.2%) 대비 4.4%, 기존 최고 성능인 ForAINetV2_R16 (87.5%) 대비 3.1%의 향상을 기록하였다.

표 3. FOR-instanceV2 테스트 분할 IoU(%) 비교 결과

방법	Ground	Wood	Leaf	mIoU
ForAINetV2_R8	98.3	68.1	94.3	86.9
ForAINetV2_R16	98.8	69.2	94.5	87.5
OneFormer3D	97.8	63.1	93.4	84.8
ForestFormer3D	96.9	67.7	94.1	86.2
Dual-Stream	99.5	76.6	95.7	90.6

3. Ablation Study

제안 아키텍처에서 각 구성 요소가 성능에 미치는 영향을 정량적으로 분석하기 위해 Ablation study를 수행하였다. 표 4는 해당 논문에서 백본으로 사용한 OA-CNNs만 사용했을 때와

Feature(FA)를 단순 결합했을 때, 그리고 Feature에 Attention 결과를 적용하여 Dual-Stream을 적용했을 때의 결과를 나타낸다.

표 4. 설계 선택에 따른 성능 비교

방법	Ground	Wood	Leaf	mIoU
OA-CNNs	98.8	72.1	94.7	88.5
OA-CNNs +FA	99.4	72.8	94.9	89.0
Dual-Stream	99.5	76.6	95.7	90.6

skeleton feature를 3D 좌표에 단순 결합한 OA-CNNs + FA는 기준 모델 대비 mIoU 0.5%, Wood IoU 0.7% 향상에 그쳤다. Ground IoU의 0.6% 개선은 skeleton feature가 정의되지 않는 ground 포인트에서 모든 feature 값이 0으로 채워지는 특성 자체가 ground와 비 ground 포인트를 구분하는 단서로 작용한 결과로 판단된다. 그러나 본질적으로 이질적인 두 종류의 정보가 동일한 convolution 연산에서 처리됨으로써, 각 도메인의 고유한 패턴이 충분히 활용되지 못하는 한계를 보인다. 반면 두 도메인을 독립 스트림으로 분리 처리하고 GeoCrossAttn으로 다중 스케일 융합하는 제안 Dual-Stream 모델은 mIoU 90.6%, Wood IoU 76.6%를 달성하여 단순 결합 방식 대비 각각 1.6%, 3.8%의 추가 향상을 기록하였다. 이는 공간 좌표와 skeleton feature를 독립적으로 처리한 뒤 GeoCrossAttn으로 융합하는 전략이 단순 concat보다 두 도메인의 정보를 효과적으로 활용함을 실험적으로 검증하였다.

4. 정성적 비교 분석

정량적 비교 결과에서 제안 모델이 줄기(Wood) 클래스에서 큰 폭의 성능 향상을 보였으나, mIoU와 같은 수치 지표만으로는 실제 어떤 영역에서 오분류가 개선되었는지, 그리고 어떤 조건에서 여전히 한계가 존재하는지 파악하기 어렵다. 이에 대하여 제안 모델의 segmentation 결과를 시각적으로 분석하여, 기존 모델 대비 개선된 영역과 오류가 있는 부

분을 분석하였다.

가. 기존 모델 대비 개선 분석

그림 5는 ForestFormer3D와 제안 모델의 segmentation 결과를 비교한 것이다. ForestFormer3D 결과에서는 수관 상부의 잎 밀집 영역에서 잎이 줄기로 과추정되는 경향이 나타나며, 빨간 화살표로 표시된 부분에서 이러한 오분류가 두드러진다. 이는 수관 내부에서 가지와 잎이 공간적으로 인접할 때 3D 좌표만으로는 두 클래스의 경계를 정밀하게 구분하기 어렵기 때문인 것으로 판단된다. 반면 제안 모델 결과에서는 동일한 영역에서 잎이 올바르게 분류되어 있음을 확인할 수 있었다. 이는 skeleton feature가 제공하는 구조적 위치 정보를 Dual-Stream 아키텍처가 효과적으로 융합함으로써, 줄기-잎 경계 영역에서의 과추정이 완화된 결과로 판단된다.




그림 5. ForestFormer3D(위) vs 제안 Dual-Stream 모델(아래) Segmentation 결과 비교 (검정: 지면, 갈색: 줄기, 초록색: 잎)

나. 오류 분석 및 한계 사례

제안 모델이 전반적으로 높은 성능을 달성하였으나, 특정 조건에서는 여전히 오분류가 발생한다. 본

항에서는 오류 유형을 분류하고, 각 원인을 분석하였다. 첫 번째로, GT 라벨링 오류에 의한 성능 과소평가 가능성이 관찰되었다. 그림 6은 다중 개체목 환경에서 GT와 제안 모델의 예측 결과를 비교한 것이다. 빨간 점선으로 표시된 하부 줄기 영역에서 GT에 옳으로 잘못 라벨링된 줄기 포인트가 혼재되어 있으며, 이는 개체목이 밀집한 환경에서 줄기 간 경계가 불명확할수록 라벨링 오류가 빈번하게 발생할 수 있음을 보여주고 있다. 이러한 GT 라벨링 오류는 모델이 해당 영역을 올바르게 예측하더라도 GT 기준 평가에서는 오분류로 산정되므로, 보고된 Wood IoU 76.6%는 제안 모델의 실질적 줄기 분류 성능의 하한값으로 해석할 수 있다. 두 번째로, 얇은 가지 영역에서의 예측 오류가 관찰되었다. 그림 7은 단일 개체목의 수관 내부 영역을 확대하여 ForestFormer3D와 제안 모델의 결과를 비교한 것이다. 그림 7의 (a) 영역에서는 제안 모델이 잎-줄기 경계를 올바르게 분류하고 있는 반면, (b) 영역에서는 제안 모델 역시 얇은 가지를 옳으로 잘못 예측하는 한계가 나타난다. 이는 LBC 알고리즘의 구조적 특성에 기인한 것으로 분석된다. LBC는 Laplacian 기반 반복 수축을 통해 포인트 클라우드를 1차원 골격으로 압축하는데, 포인트 밀도가 낮고 반경이 작은 얇은 가지 구간에서는 수축 과정이 불안정해져 skeleton 추출의 정확도가 저하된다. 이 경우 해당 포인트에 대한 DSK(Distance to Skeleton)와 ELR(Edge Local Radius) 값의 신뢰도가 낮아지며, 결과적으로 Geo Stream이 제공하는 구조적 위치 특성이 고려되지 않아 잎과의 구분이 어려워진다. 특히 수관 내부에서 얇은 가지가 잎에 둘러싸인 경우, Spatial Stream의 3D 좌표 정보 역시 잎과 유사한 분포를 보이므로 두 스트림 모두에서 줄기 판별의 단서가 부족해진다.




그림 6. 다중 개체목 환경에서의 GT 라벨링과 제안 모델이 Predict한 사례 비교. GT(좌)의 빨간 점선 영역에서 줄기 포인트가 옳으로 오분류. 제안 모델(우)에서의 올바르게 예측한 것을 볼 수 있음.




그림 7. 수관 내부 확대 비교. (a) ForestFormer3D에서 줄기를 옳으로 잘못 예측한 영역, (b) 제안 모델에서 얇은 가지를 옳으로 잘못 예측한 영역

위의 분석으로부터 제안 모델의 오류가 주로 얇은 가지에서의 LBC skeleton 추출 불안정성에 기인함을 확인하였다. 포인트 밀도가 낮고 반경이 작은 가지 구간에서는 LBC의 반복 수축이 불안정해져 skeleton feature의 신뢰도가 저하되며, 이는 제안 모델의 성능이 LBC 전처리의 과정에 의존적임을 보여준다. 향후 얇은 가지에 대한 적응적 수축 파라미터 조정이나 skeleton 추출 과정의 개선을 통해 추가적인 성능 향상이 가능할 것으로 기대된다. 또한 GT 라벨링 오류의 존재는 보고된 정량적 성능 지표가 제안 모델의 실질적 분류 능력을 보수적으로 반영하고 있음을 나타내며, 나아가 수목 포인트 클라우드 분야에서 wood와 leaf 간 경계가 모호한

영역에 대한 체계적인 라벨링 기준 수립 및 라벨 품질 검증 방법론에 대한 연구가 병행될 필요가 있음을 시사하고 있다.

V. 결론 및 향후 연구

본 연구에서는 산림 포인트 클라우드 semantic segmentation에서 수목의 위상적 구조 정보를 명시적으로 활용하기 위해, Laplacian skeleton feature 기반의 Dual-Stream OA-CNNs 아키텍처를 제안하였다. LBC 알고리즘으로부터 5가지 기하학적 feature를 설계하여 각 포인트의 구조적 위치를 다섯 가지 관점에서 인코딩하였다. Spatial Stream과 Geo Stream을 독립 처리하여 GeoCrossAttn으로 6개 스케일에서 단계적으로 융합하는 구조를 설계하였다. FOR-instanceV2 데이터셋에서 mIoU 90.6%를 달성하여 OA-CNNs 대비 2.1%, ForestFormer3D 대비 4.4% 향상을 기록하였다. Ablation study를 통해 skeleton feature의 도입(OA-CNNs → OA-CNNs + Feature, mIoU +0.5%)과 독립 스트림 분리 처리 및 GeoCrossAttn 융합(OA-CNNs + Feature → Dual-Stream, mIoU +1.6%)의 단계적 기여를 정량적으로 검증하였으며, 특히 줄기(Wood) 클래스 IoU가 72.1%에서 76.6%로 4.5% 향상되어 skeleton feature와 Dual-Stream 아키텍처의 유효성을 실증하였다. 다만 본 연구에는 몇 가지 한계가 존재한다. 첫째로, ForestFormer3D가 semantic segmentation과 instance segmentation을 end-to-end로 통합 수행하는 반면, 제안 모델은 semantic segmentation에 특화되어 있어 개체목 단위 instance segmentation을 위해서는 별도 모듈이 요구된다. 둘째, 실험이 FOR-instanceV2 단일 데이터셋에 한정되어 있어 다양한 수종·스캐닝 조건에 대한 추가 검증이 필요하다. 셋째, LBC 기반 skeleton 추출이 전처리 단계에서 별도로 수행되므로 완전한 end-to-end 학습 파이프라인이 아니다. 향후 연구에서는 instance segmentation head를 통합하여 end-to-end 파이프

라인으로 확장하고, 다양한 산림 데이터셋에 대한 교차 검증을 수행하며, skeleton feature 추출의 자동화·경량화를 통해 실용적 배포 가능성, 포인트 클라우드 내에서 skeleton 추출을 함께 학습하는 joint learning 프레임워크 연구를 수행할 예정이다.

REFERENCES

- [1] 산림면적(2021), <https://www.index.go.kr/> (accessed Mar., 15, 2026).
- [2] 이성호, 고대식, "LiDAR 기반 산림 자원 조사 기술 동향," *한국측량학회지*, 제38권, 제6호, 579-590쪽, 2020년 12월
- [3] Y. Bai, J. B. Durand, G. Vincent, and F. Forbes, "Semantic segmentation of sparse irregular point clouds for leaf/wood discrimination," in *Proc. of Neural Information Processing Systems (NeurIPS)*, vol. 36, pp. 48293-48313, Dec. 2023.
- [4] B. Xiang, M. Wielgosz, S. Puliti, K. Král, M. Krůček, A. Missarov, and R. Astrup, "ForestFormer3D: A unified framework for end-to-end segmentation of forest LiDAR 3D point clouds," *Proc. of IEEE/CVF ICCV*, Honolulu, USA, Oct. 2025.
- [5] X. Zhu, A. K. Skidmore, T. Wang, J. Liu, R. Darvishzadeh, Y. Shi, J. Premier, and M. Heurich, "Improving leaf area index (LAI) estimation by correcting for clumping and woody effects using terrestrial laser scanning," *Agricultural and Forest Meteorology*, vol. 263, pp. 276 - 286, Dec. 2018.
- [6] K. Calders, J. Adams, J. Armston, H. Bartholomeus, S. Bauwens, L. P. Bentley, J. Chave, F. M. Danson, M. Demol, M. Disney, R. Gaulton, S. M. Krishna Moorthy, S. R. Levick, N. Saarinen, C. Schaaf, A. Stovall, L. Terryn, P. Wilkes, and H. Verbeeck, "Terrestrial laser scanning in forest ecology: Expanding the horizon," *Remote Sensing of Environment*, vol. 251, Art. no. 112102, Dec. 2020.
- [7] R. J. L. Hartley, S. Jayathunga, J. Morgenroth, and G. D. Pearse, "Tree branch characterisation from point clouds: A comprehensive review," *Current Forestry Reports*, vol. 10, no. 5, pp. 360 - 385, Oct. 2024.
- [8] C.R. Qi, H. Su, K. Mo, and L.J. Guibas, "PointNet: Deep learning on point sets for 3D classification and segmentation," *Proc. of IEEE/CVF CVPR*, pp. 652-660, Honolulu, USA, Jul. 2017.

- [9] C.R. Qi, L. Yi, H. Su, and L.J. Guibas, "PointNet++: Deep hierarchical feature learning on point sets in a metric space," *Proc. of Neural Information Processing Systems (NIPS)*, vol. 30, Long Beach, USA, Dec. 2017.
- [10] X. Wu, L. Jiang, P.S. Wang, Z. Liu, X. Liu, Y. Qiao, W. Ouyang, T. He, and H. Zhao, "Point Transformer V3: Simpler, faster, stronger," *Proc. of IEEE/CVF CVPR*, pp. 4840-4851, Seattle, USA, Jun. 2024.
- [11] B. Peng, X. Wu, L. Jiang, Y. Chen, H. Zhao, Z. Tian, and J. Jia, "OA-CNNs: Omni-adaptive sparse CNNs for 3D semantic segmentation," *Proc. of IEEE/CVF CVPR*, pp. 21305-21315, Seattle, USA, Jun. 2024.
- [12] M. Kolodiazny, A. Vorontsova, A. Konushin, and D. Rukhovich, "OneFormer3D: One transformer for unified point cloud segmentation," *Proc. of IEEE/CVF CVPR*, pp. 20943-20953, Seattle, USA, Jun. 2024.
- [13] J. Cao, A. Tagliasacchi, M. Olson, H. Zhang, and Z. Su, "Point cloud skeletons via Laplacian-based contraction," in *Proc. of Shape Modeling International (SMI)*, pp. 187-197, Aix-en-Provence, France, Jun. 2010.
- [14] Y. Livny, F. Yan, M. Olson, B. Chen, H. Zhang, and J. El-Sana, "Automatic reconstruction of tree skeletal structures from point clouds," *ACM Transactions on Graphics*, vol. 29, no. 6, Art. no. 151, Dec. 2010.
- [15] L. Meyer, A. Gilson, O. Scholz, and M. Stamminger, "CherryPicker: Semantic skeletonization and topological reconstruction of cherry trees," *Proc. of IEEE/CVF CVPR Workshops*, pp. 6244-6253, Vancouver, Canada, Jun. 2023.
- [16] N. Sharp and K. Crane, "A Laplacian for nonmanifold triangle meshes," *Computer Graphics Forum*, vol. 39, no. 5, pp. 69-80, Aug. 2020.
- [17] Z. Zhuang, R. Li, K. Jia, Q. Wang, Y. Li, and M. Tan, "Perception-aware multi-sensor fusion for 3D LiDAR semantic segmentation," in *Proc. of IEEE/CVF ICCV*, pp. 16280-16290, Montreal, Canada, Oct. 2021.
- [18] J. Li, H. Dai, H. Han, and Y. Ding, "MSeg3D: Multi-modal 3D semantic segmentation for autonomous driving," in *Proc. of IEEE/CVF CVPR*, pp. 21694-21704, Vancouver, Canada, Jun. 2023.

 저자 소개



박한음(준회원)

2018년 전남대학교(여수캠퍼스) 멀티미디어 학과 학사 졸업.

<주관심분야 : 로봇 지능, IoT 시스템, 데이터분석>



정희용(정신회원)

2002년 부경대학교 제어계측공학과 학사 졸업.

2004년 Hiroshima University 로봇공학과 석사 졸업

2009년 Osaka University 기계공학과 박사 졸업.

<주관심분야 : 로봇지능, IoT 시스템, 데이터분석>



김광일(정회원)

2016년 전남대학교 임학과 학사 졸업.

2022년 전남대학교 임학과 석사 졸업.

2026년 전라남도산림연구원 녹지연구사

<주관심분야 : 산림 원격탐사, 데이터 분석>