

저비용 3D LiDAR 기반 객체 탐지 효율적 최적화 방안 연구

A Study on Efficient Optimization Methods for Low-cost 3D LiDAR-based Object Detection

김 준 형¹, 김 민 창², 박 형 준³, 김 도 선¹, 장 하 늘¹, 김 태 웅¹, 강 창 목^{1,*}

(Junhyeong Kim¹, Minchang Kim², Hyungjun Park², Doseon Kim³, Haneul Jang¹, Taewoong Kim¹, and Chang Mook Kang^{1,*})

¹Department of Electrical Engineering, Hanyang University, Seoul 04763, Korea

²Department of Artificial Intelligence, Hanyang University, Seoul 04763, Korea

³Department of Mechatronics Engineering, Incheon National University, Incheon 22012, Korea

Abstract: Recent research has focused on integrating low-cost 3D LiDAR sensors into vehicles to advance autonomous driving technologies. However, most 3D object detection algorithms are developed and validated using high-cost 3D LiDAR sensors. Therefore, this study evaluates the performance of current 3D object detection algorithms within a low-cost 3D LiDAR environment and provides a comparative analysis to identify their effectiveness.

Keywords: autonomous vehicle, LiDAR, deep learning, point cloud, object detection, low cost

I. 서론

자율주행 차량·로봇에서 환경 인식은 안전성과 효율성 확보의 핵심이다. 특히 객체의 거리·크기·위치를 3차원적으로 인식하는 센서 기술은 경로 계획, 충돌 회피, 상호작용 등 다양한 기능에 필수이며, 대표적으로 LiDAR가 활용된다. 기존 고성능 LiDAR는 높은 해상도와 정밀한 포인트 클라우드를 제공해 3D 객체 탐지와 공간 이해에 효과적이지만, 높은 가격·전력 소모·기계적 복잡성으로 상용화에 제약이 있다. 반면 Yujin YRL3, Livox MID 시리즈 등 저비용 센서는 도입 비용을 줄일 수 있으나 낮은 채널 수와 비정형 스캔으로 포인트 밀도와 인식 성능이 떨어지는 한계가 있다. 본 연구에서는 이러한 한계를 극복하기 위해, 저비용 LiDAR 3종(YRL3, MID-70, VLP-16)을 대상으로 3D 객체 탐지 알고리즘(SECOND, PART-A2-Free)을 적용하고, 전처리 기법 적용 전후의 성능을 비교·분석하였다. 특히 다중 프레임 누적·클러스터링·업샘플링 기반 전처리는 낮은 점밀도를 보완하고 객체 윤곽을 복원해 소형·원거리 객체 탐지를 개선하며, 추가 하드웨어 비용 없이도 고성능 LiDAR에 준하는 성능을 확보할 수 있는 장점이 있다. 이를 통해 저비용 센서 환경에서도 탐지 성능을 확보할 최적 조합을 제시하고, 비용 효율적 센서-소프트웨어 통합 전략 수립에 기여한다.

II. 관련 연구

초기 3D 객체 탐지 방법은 LiDAR Point Cloud에 대한 클러스터링 및 분류와 같은 수작업 파이프라인에 의존하였다. 그러나 딥러닝의 발전으로 Point Cloud를 직접 입력으로 사용하는 VoxelNet 등이 제안되면서 학습 기반 탐지 성능이 크게 향상되었다. VoxelNet 이후, SECOND 알고리즘은 Sparse Convolution 기반의 효율적인 3D CNN을 도입하여 처리 속도를 높이고 정확도를 개선하였으며, 이는 3D 객체 탐지 분야의 주요 1단계(voxel 기반) 접근법으로 자리매김하였다. 한편, PointPillars [2]는 PointNet으로 포인트들을 수직 기둥(pillar) 단위로 임베딩해 2D CNN으로 처리하는 경량 구조를 제안, KITTI 벤치마크에서 62Hz 이상의 실시간 성능을 달성하였다. 이처럼 속도에 중점을 둔 모델과 대조적으로, Part-A2-Net은 3D 객체의 부분 정보를 활용한 2단계 검출기로서 정교한 anchor-free 방식과 후처리를 통해 정확도를 극대화하였다. Part-A2-Net은 KITTI 데이터셋 기준 최고 수준의 정확도를 보고한 바 있으며, 이후 Part-A2-Free 등 변형을 통해 다양한 LiDAR 데이터에 적용되고 있다. 또, 저비용 LiDAR를 활용한 3D Object Detection 성능을 높이려는 다양한 접근도 제안되었다. 우선 클러스터링 알고리즘의 파라미터 추론 방식을 개선해 객체 검출의 성능과 신뢰도를 높인 연구가 있었으며

* Corresponding Author

Manuscript received August 20, 2025; revised September 9, 2025; accepted September 30, 2025

김준형: 한양대학교 전기공학과 대학원생(ss52kjh123@hanyang.ac.kr, ORCID[®] 0009-0006-7561-7277)

김민창: 한양대학교 인공지능학과 대학원생(chang000828@hanyang.ac.kr, ORCID[®] 0009-0004-7407-072X)

박형준: 한양대학교 인공지능학과 대학원생(phj990608@hanyang.ac.kr, ORCID[®] 0009-0005-5072-2807)

김도선: 인천대학교 메카트로닉스공학과 대학원생(ehdms1412@inu.ac.kr, ORCID[®] 0009-0008-4020-7889)

장하늘: 한양대학교 전기공학과 대학원생(nulha01@hanyang.ac.kr, ORCID[®] 0009-0002-2352-2656)

김태웅: 한양대학교 전기공학과 대학원생(ici1999@hanyang.ac.kr, ORCID[®] 0009-0005-7258-7386)

강창목: 한양대학교 전기공학과 교수(kcm0728@hanyang.ac.kr, ORCID[®] 0000-0003-2467-2074)

※ 본 논문은 2025년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원(No.RS-2020-II201373, 인공지능대학원지원(한양대학교), No.RS-2025-25443597, 환자 이송 및 이동 보조 자율행동체 구현을 위한 지능 기술 개발 및 실증)과 2025년도 정부(산업통상자원부)의 재원으로 한국산업기술기술평가원의 지원을 받아 수행된 연구임(No.RS-2024-00443216, No.RS-2025-13202969).

※ 이 논문은 2025 제40회 제어·로봇·시스템학회 학술대회에 초안이 발표되었음.

[3], 또한 딥러닝 기반 2D 객체 인식 모델과 저비용 LiDAR를 융합해 실시간 처리 능력과 높은 정확도를 동시에 달성한 사례도 보고되었다[4,5]. 더불어 저해상도 16채널 3D LiDAR 데이터를 카메라와 융합해 64채널 LiDAR에 준하는 성능을 구현한 연구도 존재한다[6]. 또한 저해상도 LiDAR 자체의 성능을 보완해 탐지 정확도를 향상시키려는 연구[7]도 보고되었다. 그러나 두 연구는 LiDAR 외 카메라 센서가 필수적으로 요구돼 장비 구성·시스템 복잡도 측면에서 한계를 가진다. 본 연구에서는 저비용 LiDAR 단독 환경에서의 3D Object Detection 성능을 체계적으로 평가·최적화하는 데 초점을 맞추었다.

III. 사용 장비 및 알고리즘

1. 3D LiDAR 센서 사양 비교

본 연구에서 사용된 저비용 3D LiDAR는 유진로봇사의 YRL3, Livox사의 MID-70이며 Velodyne사의 VLP-16 모델은 고가의 HDL-64E를 대체하는 기준 센서로 사용되었다. 각 센서는 서로 다른 특징과 사양을 갖추고 있으며, 이를 통해 저비용 LiDAR 환경에서의 성능 평가를 수행하였다.

1.1 Yujin YRL3

Yujin YRL3는 실내 자율주행 로봇용으로 개발된 저비용 3D LiDAR로, 수평 270°×수직 90°의 시야각을 가지며 최대 약 20m 범위의 객체를 감지할 수 있다. YRL3는 소형 경량으로 가격이 저렴하지만, 레이저 출력 채널 수가 1채널로 포인트 클라우드의 점밀도가 매우 낮다.

1.2 Livox MID-70

Livox MID-70는 DJI의 LiVOX 시리즈 중 중간급에 해당하는 솔리드스테이트 LiDAR로, 약 70°의 시야를 가지며 Rosette 패턴의 비균일 스캔을 특징으로 한다. 이 센서는 한 프레임에서 조사되는 점들이 무작위 분포를 보이지만, 여러 프레임을 합치면 시야 전체에 균일에 가까운 커버리지를 제공한다. Livox MID-70의 유효 감지거리는 270m이다.




그림 1. 유진 YRL3.

Fig. 1. Yujin YRL3.




그림 2. 유진 YRL3의 점군 데이터.

Fig. 2. Point Cloud Data of Yujin YRL3.



그림 3. 리복스 MID-70.

Fig. 3. Livox MID-70.




그림 4. 리복스 MID-70의 점군 데이터.

Fig. 4. Point Cloud Data of Livox MID-70.

1.3 Velodyne VLP-16

Velodyne VLP-16은 16채널 레이저를 360° 회전시키는 기계식 LiDAR로, 수직 30°(±15°) 범위에 걸쳐 레이저를 배치하여 프레임당 약 30만~40만 개의 포인트를 생성한다. VLP-16은 자동차용으로 널리 활용되는 보급형 LiDAR로서, 최대 100m 내외의 범위를 커버하며 상대적으로 컴팩트하고 비용이 Velodyne의 고사양 모델보다 저렴하다.

2. 3D 객체 탐지 알고리즘 소개

비교 실험에 사용된 2가지 3D 객체 탐지 딥러닝 알고리즘은 모두 LiDAR 포인트 클라우드를 입력으로 동작하지만, 내부 표현과 구조에서 차이가 있다.



그림 5. 벨로다인 VLP-16.

Fig. 5. Velodyne VLP-16.




그림 6. 벨로다인 VLP-16의 점군 데이터.

Fig. 6. Point Cloud Data of Velodyne VLP-16.

2.1 SECOND

SECOND (Sparsely Embedded Convolutional Detection)는 VoxelNet 기반 1단계 검출기로, 전체 포인트 클라우드를 3Dvoxel 격자로 변환한 뒤 sparse 3D Convolution 연산을 통해 특징 맵을 추출한다. SECOND는 anchor 박스를 활용하여 물체의 3D bounding box를 예측하며, Sparse Convolution을 도입함으로써 연산 효율을 높여 기존 VoxelNet 대비 실시간 처리에 근접하는 성능을 달성하였다.

2.2 PART-A2-Free

PART-A2-Free는 Part-A2-Net의 anchor-free 변형으로, 2단계 구조를 통해 정확도를 극대화한 알고리즘이다. 1단계에서는 Point Cloud 상의 object proposal을 부분 객체 단위 특징으로 예측하고, 2단계에서는 RoI 영역의 포인트를 pooling하여 bounding box를 정교하게 보정한다. 이러한 part-aware 접근은 추가 비용 없이 학습된 3D 박스의 내부 점 분포를 활용함으로써 작은 물체도 세밀하게 감지할 수 있게 한다. PART-A2-Free는 anchor box를 사용하지 않음으로써 복잡한 튜닝 없이도 높은 재현율(Recall)을 얻는 장점이 있으며, KITTI 벤치마크 등에서 최고 수준의 mAP를 보고하였다.

IV. 실험 설계 및 데이터 전처리

1. 데이터 수집 조건 및 환경

실험에서 사용된 Point Cloud 데이터는 실내 환경에서 수집되었으며, Yujin YRL3는 지면에 직접 배치, Livox MID-70 및 Velodyne VLP-16은 지면에서 80cm의 높이에 배치하였다. 데이터는 보행자를 대상으로 수집하였으며, 실험에 사용된 저비용 LiDAR 중 유진로봇의 YRL3는 실내용 LiDAR로 개발된 센서이므로 이에 맞추어 실내 및 근거리 환경에서 가장 흔히 나타나는 객체인 보행자를 대상으로 설정하였다. 데이터 수집 시나리오는 LiDAR 센서의 객체 탐지 성능을 포괄적으로 평가하기 위해 보행자 수 및 이동 방향을 다양하게 설정하여 1~4명의 보행자가 종방향 및 횡방향으로 이동하는 8가지의 상황을 가정하여 구성하였다. 이때, LiDAR 센서별 데이터 특성과 탐지 성능을 비교분석하기 위해 동일한 환경에서 수집이 이루어졌으며 각 시나리오별 100개의 데이터를 수집하여 실험을 진행하였다.

2. 전처리 기법

저비용 LiDAR의 원시 포인트 클라우드는 센서 구조적 특성으로 인해 밀도 부족, 공간 분포 불균형, 노이즈 등의 문제가 발생하기 쉬우며, 이러한 한계는 3D 객체 탐지 알고리즘의 성능 저하로 이어질 수 있다. 특히 저채널 혹은 비정형 스캔 구조를 가진 센서에서는 동일한 객체가 프레임마다 다르게 표현되거나, 배경과 객체 간의 경계가 흐려지는 문제가 발생한다. 본 연구에서는 이러한 특성을 보완하기 위해 센서별로 맞춤형 전처리 기법을 적용하였다.

Velodyne VLP-16은 수직 16채널 구조를 갖는 기계식 회전형 LiDAR로, 프레임당 다수의 포인트를 균일하게 생성할 수 있기 때문에, 별도의 전처리 없이도 높은 품질의 포인트 클라우드를 확보할 수 있었다. 이에 따라 해당 센서의 데이터에는 추가적인 보정 작업을 수행하지 않고 원본 그대로 알고리즘을 적용하였다.

반면, Yujin YRL3는 단일 레이저 채널을 수직 방향으로 회전시켜 데이터를 획득하는 방식으로, 한 프레임에서 생성되는 포인트 수가 현저히 적고, 특정 영역(수평면)에만 밀집된 형태를 보인다. 이러한 낮은 점밀도를 보완하기 위해, 본 연구에서는 다중 프레임 누적 기반의 assembling 기법을 적용하였다. 이는 시간적으로 인접한 여러 프레임을 정렬하여 단일 시점의 고밀도 포인트 클라우드로 병합하는 방식이다. 정합 시에는 보행자나 기타 동적 객체의 움직임을 고려하여 정적 배경 제거 알고리즘을 먼저 적용하였으며, 이를 통해 이동 객체에 대한 탐지 집중도를 높이고 배경 잡음을 최소화하였다. 이후 Euclidean Distance 기반의 클러스터링 기법을 통해 포인트를 객체 단위로 분할하고, 각 클러스터에 대해 MLS (Moving Least Squares) 보간법을 적용하여 곡면 구조를 복원하였다. MLS 기반 업샘플링은 특히 포인트 간 간격이 넓거나 형상이 단순한 경우에 효과적으로 적용되며, 보행자의 윤곽이나 자세한 형태를 보다 명확하게 부각시킬 수 있었다.

표 1. 저가형 LiDAR 전처리 과정.

Table 1. Low-Cost LiDAR Preprocessin.

1	Preprocess_LiDAR(PointCloud, SensorType):
2	Input: Raw PointCloud from LiDAR sensor
3	SensorType $\in$ {YRL3, MID-70, VLP-16}
4	Output: Preprocessed PointCloud
5	# Step 1. Sensor-specific processing
6	if SensorType == YRL3 :
7	PointCloud
8	$\leftarrow$ Assemble_Frames(PointCloud, n_frames)
9	else if SensorType == MID-70 :
10	PointCloud $\leftarrow$ PointCloud
11	else if SensorType == VLP-16 :
12	return PointCloud
13	
14	# Step 2. Static background removal
15	PointCloud
16	$\leftarrow$ Remove_Static_Background(PointCloud)
17	
18	# Step 3. Clustering (Euclidean Distance-based)
19	Clusters $\leftarrow$ []
20	for each point p in PointCloud :
21	if Distance(p, neighbor_points) $< \epsilon$:
22	Add p to cluster
23	Remove clusters smaller than threshold θ
24	# Step 4. Surface reconstruction and upsampling (MLS)
25	for each cluster C in Clusters :
26	Surface $\leftarrow$ Estimate_Local_Surface(C)
27	C $\leftarrow$ MLS_Upsampling(C, Surface)
28	
29	# Step 5. MID-70 specific tuning
30	if SensorType == MID-70 :
31	Adjust clustering parameters:
32	MinClusterSize $\uparrow$, DistanceThreshold $\downarrow$
33	return Combined_Clusters(Clusters)

표 2. 전처리 전과 후의 성능 비교.

Table 2. Performance comparison before and after preprocessing.

LiDAR	Model	Precision(%)		Recall(%)		F1 Score		Runtime(s)	
		Before	After	Before	After	Before	After	Before	After
YRL3	SECOND	98	98.89	8.82	42.88	11.33	49.85	0.034	0.035
	PART-A2-FREE	99.81	98.9	20.12	87.71	25.84	90.35	0.044	0.053
MID-70	SECOND	62.3	95.49	63.05	88.4	55.77	88.76	0.037	0.037
	PART-A2-FREE	100	82.68	54.92	91.84	62.44	85.16	0.05	0.061

표 3. 3D 객체 탐지 성능 비교.

Table 3. Performance comparison of 3D object detection.

LiDAR	Model	Precision(%)	Recall(%)	F1 Score	Runtime(s)
YRL3	SECOND	98.89	42.88	49.85	0.035
	PART-A2-FREE	98.9	87.71	90.35	0.053
MID-70	SECOND	95.49	88.4	88.76	0.037
	PART-A2-FREE	82.68	91.84	85.16	0.061
VLP-16	SECOND	81.51	90.8	83.8	0.037
	PART-A2-FREE	99.8	86.54	89.52	0.058

Livox MID-70은 Solid-State 기반 센서로서 Rosette 방식의 비정형 스캔 패턴을 사용한다. 이 센서는 한 프레임 내 포인트들이 균등하지 않게 분포하며, 프레임 간 누적 시에야 전체 시야에 걸친 커버리지를 확보할 수 있는 특성이 있다. 그러나 본 연구에서는 단일 프레임 기준의 실시간 탐지 가능성을 고려하여 단일 프레임 기반 전처리 기법을 적용하였다. MID-70의 경우도 포인트 분포의 공간적 편향과 밀도 불균형 문제가 존재하므로, YRL3와 동일하게 정적 배경 제거, Euclidean 클러스터링, MLS 업샘플링의 3단계 과정을 적용하였다. 특히, MID-70은 객체가 불균일하게 묘사되는 경향이 있기 때문에 클러스터링 파라미터(예: 최소 클러스터 크기, 거리 임계값)를 보다 엄격하게 설정하여 잘못된 군집화를 방지하였다.

추가적으로 MID-70의 데이터는 Velodyne 기반 알고리즘에서 가정하는 균일한 수직 해상도와 차이가 크기 때문에, 초기에 pattern alignment 기법을 도입해 Rosette 스캔을 voxel grid 상에서 보정하는 실험도 수행하였다. 그러나 실제 실험 결과, 해당 기법은 오히려 포인트 간의 위상 왜곡을 초래해 전체적인 탐지 성능을 저하시켰으며, 따라서 본 연구에서는 최종적으로 이를 생략하고 원 포인트 분포 기반의 전처리만을 적용하였다.

결론적으로, YRL3와 MID-70은 모두 포인트 수와 분포의 한계로 인해 전처리 없이는 효과적인 탐지가 어려웠으며, 본 연구에서 제안한 다단계 전처리 기법(다중 프레임 누적, 클러스터링, 업샘플링 등)을 통해 구조 보완과 밀도 향상을 동시에 달성할 수 있었다. 이는 탐지 알고리즘에 전달되는 입력 품질을 높여, 이후 단계에서의 성능 향상으로 직접 이어졌다. 센서별 특성에 최적화된 전처리 설계는 저비용 LiDAR를 실용적으로 활용하기 위한 핵심 기술로 평가된다.

3. 알고리즘 적용 조건 및 평가 지표

두 가지 탐지 알고리즘(SECOND, PART-A2-Free)은 모두 OpenPCDet 라이브러리를 기반으로 활용하였다. SECOND는 본 연구에서 직접 11 epoch 동안 학습하여 생성한 모델을 사

용하였으며, PART-A2-Free는 라이브러리에서 제공하는 사전 학습된 모델(pre-trained model)을 그대로 사용하였다. 두 알고리즘 모두 추가적인 fine-tuning 없이, 센서 특성에 따라 최소한의 파라미터만 조정하여 저비용 LiDAR 데이터셋(YRL3, Livox MID-70, Velodyne VLP-16)에 적용하였다. 예를 들어, YRL3 센서의 낮은 포인트 밀도를 고려하여 PART-A2-Free 모델의 경우 part 분할 시 요구되는 최소 포인트 수(minimum point threshold)를 조정함으로써, 저해상도 데이터에서도 객체 탐지가 원활히 이루어지도록 설정하였다.

성능 평가는 Precision, Recall, F1 Score, Runtime의 4가지 지표로 이루어졌다. Precision은 탐지한 객체 중 실제로 맞는 검출의 비율(정밀도)을, Recall은 실제 객체 중 탐지에 성공한 비율(재현율)을 의미한다. F1 Score는 Precision과 Recall의 조화 평균으로 계산되어, 두 지표 간의 균형을 한눈에 보여준다. Runtime은 알고리즘이 한 프레임의 Point Cloud 데이터를 입력받아 탐지를 완료하는 데 소요된 처리 시간으로, 전반적인 처리 효율성을 평가하는 데 사용되었다.

모든 실험은 Intel Core Ultra9 CPU, RAM 32GB 및 NVIDIA RTX4070 GPU가 탑재된 ASUS NUC 14 PC에서 수행되었으며, 알고리즘 구동은 Ubuntu 20.04 기반의 DOCKER 환경에서 이루어졌다.




그림 7. 유진 YRL3의 전후처리.

Fig. 7. Before and After Preprocessing of Yujin YRL3.




그림 8. 리복스 MID-70의 전처리.

Fig. 8. Before and After Preprocessing of Livox MID-70.

V. 실험 결과 및 분석

본 연구에서는 저비용 3D LiDAR 센서 3종(YRL3, MID-70, VLP-16)을 대상으로, 3D 객체 탐지 알고리즘 SECOND와 PART-A2-Free의 성능을 비교 분석하였다. 실험은 동일한 실내 환경과 시나리오에서 진행되었으며, 각 센서에 대해 전처리 전후의 성능 변화(표 1), 그리고 최종 탐지 정확도 비교(표 2)를 통해 평가를 수행하였다.

1. 전처리 전과 후의 성능 비교

표 1은 YRL3와 MID-70에 전처리 적용 전후 SECOND와 PART-A2-Free 알고리즘의 F1 Score 변화를 나타낸다. 분석 결과, 전처리의 유무가 성능에 미치는 영향이 매우 컸으며, 특히 저해상도 센서일수록 그 효과가 두드러졌다.

YRL3의 경우, 단일 채널 구조로 인해 포인트 밀도가 매우 낮아 프레임 assembling을 적용한 데이터를 '전처리 전'으로 정의하였고, 전처리 전에는 SECOND가 28.32, PART-A2-Free가 33.65의 낮은 F1 Score를 기록하였다. 그러나 전처리 적용 이후 SECOND는 Recall이 8.82%에서 42.88%로 증가하였으며, 이에 따라 F1 Score는 11.33에서 49.85로 약 340.1% 향상되었다. PART-A2-Free는 Precision 99.81%를 유지한 채, Recall이 20.12%에서 87.71%로 상승하며 F1 Score가 25.84에서 90.35로 약 249.6% 향상되어 전체 실험 중 가장 두드러진 성능 개선을 보였다.

MID-70은 비정형 Rosette 스캔 패턴을 갖고 있음에도 전처리 후 성능이 크게 향상되었다. SECOND의 Recall은 63.05%에서 88.4%로 증가했고, F1 Score는 55.77에서 88.76으로 약 59.2% 향상되었다. PART-A2-Free 또한 Recall이 54.92%에서 91.84%로, F1 Score는 62.44에서 85.16으로 각각 상승하며 약 36.4%의 향상폭을 기록했다.

이러한 결과는 전처리 과정이 센서의 구조적 한계를 극복하는 데 효과적임을 보여준다. 특히 Recall 지표가 모든 모델에서 크게 향상되었으며, 이는 전처리로 인해 객체를 놓치는 경우가 현저히 줄었음을 의미한다.

또한 Runtime 측면에서는 전처리로 인해 소폭 증가가 있었으나, 평균 증가 폭은 0.01초 내외로 실시간 처리에 큰 영향을 주지 않는 수준이었다.

2. 최종 객체 탐지 성능 비교

표 2에서는 각 센서별 알고리즘 성능 차이를 종합 비교하였으며, 전처리 적용 여부와 상관없이 PART-A2-Free가 전반적으로 SECOND보다 우수한 성능을 보였다. 특히, PART-A2-Free는 anchor-free 방식과 part-aware 구조를 활용하여 객체




그림 9. 유진 YRL3의 객체 탐지 결과.

Fig. 9. Object detection result of Yujin YRL3.




그림 10. 리복스 MID-70의 객체 탐지 결과.

Fig. 10. Object detection result of Livox Mid-70.




그림 11. 벨로다인의 객체 탐지 결과.

Fig. 11. Object detection result of Velodyne VLP-16.

내부의 포인트 분포를 정교하게 반영할 수 있기 때문에, 포인트 밀도가 낮거나 불균형한 상황에서도 안정적인 탐지가 가능했다. SECOND는 VoxelNet 기반의 경량 구조로 실시간 처리 측면에서는 효율적이지만, 희소한 포인트 클라우드에서는 오탐(FP)이 다소 증가하는 경향이 있었으며, 이에 따라 Precision이 상대적으로 낮게 나타나는 경우가 많았다. 실제 실험에서 확인된 바와 같이, SECOND는 전처리 적용 전 탐지 범위는 넓으나 객체 외곽에 노이즈가 혼입되어 정확한 bounding box 생성에는 한계가 있었다. PART-A2-Free는 특히 MID-70과 YRL3와 같은 불균일 분포의 포인트 클라우드에서도 높은 Recall을 유지하면서도 Precision 저하 없이 성능을 유지했으며, 이로 인해 전반적인 F1 Score 향상이 두드러졌다.

VI. 결론

저비용 LiDAR 환경에서의 3D 객체 탐지는 고가 센서를 활용한 기존 연구에 비해 여러 제약이 존재함에도 불구하고, 본 연구는 적절한 알고리즘 선택과 전처리 기법을 통해 그 한계를 극복할 수 있음을 실험적으로 입증하였다. 특히 PART-A2-Free 알고리즘은 SECOND 대비 전반적으로 더 높은 정밀도 및 재현율을 보이며, F1 Score 기준으로도 가장 우수한 성능을 나타냈다. 이는 anchor-free 방식과 part-aware 구조가 희소하거나 비정형적인 포인트 클라우드에서도 강건하게


작동함을 시사한다. 또한, 전처리 기법을 적용할 경우 YRL3 및 MID-70 센서 모두에서 F1 Score가 유의미하게 향상되었으며, 이는 전처리가 저해상도 센서 데이터의 품질을 개선하여 알고리즘의 탐지력을 높이는 데 결정적 역할을 한다는 사실을 뒷받침한다. KITTI와 같은 대규모 공개 데이터셋은 주로 고성능 LiDAR를 기반으로 구축되어 있어, 이를 그대로 저비용 센서에 적용할 경우 도출되는 성능 격차는 자연스러운 결과이다. 그러나 본 연구는 이와 같은 성능 저하가 단순히 하드웨어의 한계 때문만은 아니며, 적절한 알고리즘 구조와 전처리 기술의 조합을 통해 상당 부분 보완될 수 있음을 보였다. 특히, VLP-16 대비 YRL3와 MID-70도 95% 이상의 상대 성능을 보이며, 가격 대비 탐지 성능 면에서 높은 실용성을 보여주었다.

향후 연구에서는 다음과 같은 방향으로 확장을 고려할 수 있다. 첫째, 알고리즘의 구조적 경량화 및 하드웨어 최적화를 통해 실시간 처리 능력을 높이는 연구가 요구된다. 둘째, 전처리 과정의 자동화 및 보편화를 위해 센서 특성에 관계없이 적용 가능한 범용 전처리 파이프라인을 구축할 수 있다.

마지막으로, 보행자 외의 다양한 객체 클래스(예: 차량, 장애물 등)에 대한 탐지 확장도 저비용 LiDAR의 실제 활용성을 더욱 넓혀줄 수 있다. 이러한 방향으로의 연구 확장은 저비용 LiDAR 기반 자율 시스템의 범용성과 실용성을 동시에 강화하는 데 기여할 것으로 기대된다.

REFERENCES

- [1] Y. Yan, Y. Mao, and B. Li, "Second: Sparsely embedded convolutional detection," *Sensors*, vol. 18, no. 10, pp. 3337, Oct.2018
- [2] Y. Zhou and O. Tuzel, "VoxelNet: End-to-end learning for point cloud based 3D object detection," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.4490-4499, 2018.
- [3] Y. Yan, Y. Mao, and B. Li, "Second: Sparsely embedded convolutional detection," *Sensors*, vol.18, no.10, pp. 3337-3353, 2018.
- [4] A. H. Lang, S. Vora, H. Caesar, L. Zhou, J. Yang, and O. Beijbom, "PointPillars: Fast encoders for object detection from point clouds," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.12697-12705, 2019.
- [5] S. Shi, Z. Wang, J. Shi, X. Wang, and H. Li, "From points to parts: 3D object detection from point cloud with part-aware and part-aggregation network," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol.43, no.8, pp.2647-2664, 2020.
- [6] D. H. Kim and J. H. Ahn, "Improved Parameter Inference for Low-cost 3D LiDAR-based object detection on clustering algorithms," *Journal of Internet Computing and Services*, vol.23, no.6, pp.71-78, 2022.
- [7] A. J. Lee, Y. J. Hwang, B. I. Jeong, and K. Y. Lee, "Development of a real-time 3D object detection system using a deep learning-based 2D object recognition model and low-cost LiDAR sensor," *Proceedings of the Korea Information Processing Society Annual Conference*, pp.716-717, 2023.
- [8] L. Bai, Y. Zhao and X. Huang, "Enabling 3D object detection with a low-resolution LiDAR," *IEEE Embedded Systems Letters*, vol.14, no.4, pp. 163-166, 2022.
- [9] J.-H. Lee and D. Chang, "RGB camera and LIDAR fusion preprocessing algorithm for pedestrian 3D object detection," *Proceedings of the 2023 38th ICROS Annual Conference (ICROS 2023)*, Samcheok, Korea, Jun. pp. 771-772, 2023.
- [10] G. Lee, K. Kim, J. Lee, and H. Kim, "Realtime and integrated framework for LiDAR-based object tracking," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 31, no. 3, pp. 196-205, 2025.
- [11] S. H. Lee and W. Y. Choi, "Camera and LiDAR sensor fusion method for object estimation of intelligent robots," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 30, no. 8, pp. 810-816, 2024. doi: 10.5302/J.ICROS.2024.24.0104



김 준 형

2025년 인천대학교 정보통신공학과 (공학사). 2025~현재 한양대학교 전기공학과 석사과정 재학 중. 관심분야는 자율주행, 로보틱스, Computer Vision 등.



김 민 창

2025년 인천대학교 메카트로닉스공학과 (공학사), 2025~현재 한양대학교 인공지능학과 석박사통합과정 재학 중. 관심분야는 자율주행, 최적제어, 머신 러닝 등.



박 형 준

2025년 인천대학교 메카트로닉스공학과 (공학사), 2025~현재 한양대학교 인공지능학과 석박사통합과정 재학 중. 관심분야는 로보틱스, 강화학습, Physical AI 등.



김 도 선

2020년~현재 인천대학교 메카트로닉스공학과 재학 중 관심분야는 자율주행, 최적제어, physical AI 등.



장 하 늘

2025년 인천대학교 컴퓨터공학부 (공학사). 2025~현재 한양대학교 전기공학과 석사과정 재학 중. 관심분야는 자율주행, 로보틱스, 강화학습, Social Navigation 등.

**김 태 웅**

2025년 인천대학교 기계공학과(공학사).
2025~현재 한양대학교 전기공학과 석사
과정 재학 중. 관심분야는 자율주행, 최
적제어, 강화학습 등.

**강 창 목**

2012년 한양대학교 전기공학과(공학사).
2018년 한양대학교 전기공학과(공학박
사). 2018년~2019년 국방과학연구소 선
임연구원. 2019년~2025년 인천대학교 전
기공학과 교수. 2025년~현재 한양대학교
전기공학과 교수. 관심분야는 선형시스
템, 최적제어, 자율주행, 인공지능 등.