



(19) 대한민국 지식재산처(KR)

(12) 등록특허공보(B1)

(45) 공고일자 2025년11월13일

(11) 등록번호 10-2885733

(24) 등록일자 2025년11월10일

(51) 국제특허분류(Int. Cl.)

G06V 10/80 (2022.01) G06N 3/0464 (2023.01)

G06N 3/08 (2023.01) G06V 10/82 (2022.01)

G06V 20/56 (2022.01) G06V 20/64 (2022.01)

(52) CPC특허분류

G06V 10/803 (2023.08)

G01S 17/86 (2020.01)

(21) 출원번호 10-2024-0197774

(22) 출원일자 2024년12월26일

심사청구일자 2024년12월26일

(56) 선행기술조사문헌

Shaoshuai Shi 외 6명, "PV-RCNN: Point-Voxel Feature Set Abstraction for 3D Object Detection", CVPR, pp10526-10535(2020.08.05.)
1부.*

(뒷면에 계속)

전체 청구항 수 : 총 9 항

심사관 : 정수진


(54) 발명의 명칭 Camera+LiDAR 기반의 포인트 클라우드 증강 기법을 통한 3D 객체감지 성능향상 시스템 및 그 방법

(57) 요약

본 발명은 3D 객체감지 성능향상 시스템에 관한 것이며, Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템에 관한 것이다. 본 발명에 따르면, 카메라 이미지를 입력받아 깊이 지도(Depth Map)를 생성하고 이를 기반으로 Pseudo-LiDAR를 생성하며, 생성된 Pseudo-LiDAR의 intensity를 로그 스케일로

(뒷면에 계속)

대표도 - 도1



재구성하는 Pseudo-LiDAR 생성부(100), 생성된 Pseudo-LiDAR와 LiDAR 데이터를 융합하여 증강된 포인트 클라운드를 생성하며, LiDAR의 한계를 보완하고 데이터 밀도를 높이는 포인트 클라우드 증강부(200), 증강된 포인트 클라운드를 학습된 PV-RCNN 딥러닝 모델에 입력하여 3D 객체 감지를 수행하는 3D 객체 감지부(300), 3D 객체 감지 결과를 시각화하거나 외부 시스템에 제공하는 결과 출력부(400)를 포함하여 LiDAR와 Pseudo-LiDAR 데이터를 융합하여 3D 객체 감지 성능을 향상시키고, 딥러닝 모델(PV-RCNN)을 통해 효율적이고 신뢰성 있는 객체 감지를 가능하게 한다.

(52) CPC특허분류

- G01S 17/894 (2022.01)
- G01S 17/931 (2020.01)
- G06N 3/0464 (2023.01)
- G06N 3/08 (2023.01)
- G06V 10/82 (2022.01)
- G06V 20/56 (2023.08)
- G06V 20/64 (2023.08)
- G06T 2207/10028 (2013.01)
- G06V 2201/12 (2022.01)

(56) 선행기술조사문헌

- Stephen Crouch 외 3명, “Three-dimensional digital holographic aperture synthesis for rapid and highly-accurate large-volume metrology”, SPIE, Vol.9576, pp.1-7(2015.09.01.) 1부.*
- 한국 공개특허공보 제10-2023-0026130호(2023.02.24.) 1부.*
- 한국 공개특허공보 제10-2024-0006531호(2024.01.15.) 1부.*
- 한국 공개특허공보 제10-2024-0169465호(2024.12.03.) 1부.*
- *는 심사관에 의하여 인용된 문헌

이 발명을 지원한 국가연구개발사업

- 과제고유번호 2710013554
- 과제번호 2022R1F1A1066371
- 부처명 과학기술정보통신부
- 과제관리(전문)기관명 한국연구재단
- 연구사업명 개인기초연구(과기정통부)
- 연구과제명 메타버스 콘텐츠에서 사용할 수 있는 음성에 따른 자연스러운 감정 표현이 가능한

3D 얼굴 자동 생성 솔루션 개발

- 과제수행기관명 국립한밭대학교
- 연구기간 2024.03.01 ~ 2025.02.28

이 발명을 지원한 국가연구개발사업

- 과제고유번호 1345370812
- 과제번호 2021RIS-004
- 부처명 교육부
- 과제관리(전문)기관명 한국연구재단
- 연구사업명 지자체대학협력기반지역혁신사업
- 연구과제명 (대전세종충남지역혁신플랫폼)충남대학교
- 과제수행기관명 충남대학교
- 연구기간 2024.03.01 ~ 2025.02.28

명세서

청구범위

청구항 1

카메라 이미지를 입력받아 깊이 지도(Depth Map)를 생성하고 이를 기반으로 Pseudo-LiDAR를 생성하며, 생성된 Pseudo-LiDAR의 포인트별 intensity 값을 거리 기반으로 정규화하고 로그 스케일로 재구성하는 Pseudo-LiDAR 생성부(100),

생성된 Pseudo-LiDAR와 LiDAR 데이터를 정량적으로 융합하여 복셀 밀도를 비교한 후 부족 영역을 보완하여 증강된 포인트 클라우드를 생성함으로써, LiDAR의 거리 감쇠 및 탐지 누락 한계를 보완하는 포인트 클라우드 증강부(200),

증강된 포인트 클라우드를 복셀 기반 특징 추출과 포인트 기반 특징 복원을 결합한 PV-RCNN 딥러닝 모델에 입력함으로써, 원거리 객체 탐지 정확도를 향상시키는 3D 객체 감지부(300),

3D 객체 감지 결과를 시각화하거나 외부 시스템에 제공하는 결과 출력부(400)를 포함하는 것을 특징으로 하는 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템.

청구항 2

제1항에 있어서,

상기 Pseudo-LiDAR 생성부(100)는,

카메라 이미지로부터 생성된 깊이 지도(Depth Map)를 이용하여 각 픽셀의 3D 공간 좌표를 계산하며,

깊이 지도(Depth Map)와 픽셀 좌표를 기반으로 Pseudo-LiDAR를 생성하는 과정에서 좌표계와 데이터 정규화를 수행하는 것을 특징으로 하는 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템.

청구항 3

제1항 또는 제2항에 있어서,

상기 Pseudo-LiDAR 생성부(100)는,

Pseudo-LiDAR의 반사 강도 값(intensity 값)을 거리 값에 따라 로그 스케일로 변환하여 근거리와 원거리 객체의 반사 강도의 차이를 반영하는 것을 특징으로 하는 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템.

청구항 4

제1항에 있어서,

상기 포인트 클라우드 증강부(200)는,

Pseudo-LiDAR와 LiDAR 데이터 간 좌표계 정규화 및 범위 정규화를 수행하고,

두 포인트 클라우드의 복셀 밀도를 비교하여 밀도가 낮은 영역을 보완하는 방식으로 증강된 포인트 클라우드를 생성하는 것을 특징으로 하는 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템.

청구항 5

제1항에 있어서,

상기 포인트 클라우드 증강부(200)는,

Pseudo-LiDAR가 생성한 원거리 객체의 포인트 데이터를 LiDAR 포인트 클라우드의 부족한 영역에 추가하여 LiDAR

의 감지 범위를 확장하는 것을 특징으로 하는 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템.

청구항 6

제1항에 있어서,

상기 3D 객체 감지부(300)는,

복셀 기반(Voxel-based) 접근법과 포인트 기반(Point-based) 접근법을 결합한 PV-RCNN 딥러닝 모델을 사용하며, 복셀화(Voxelization)를 통해 데이터 처리량을 줄이고 계산 효율을 향상시키며, 포인트 단위 특징(Point-wise Feature) 학습을 통해 세부 정보를 복구하여 감지 정확도를 높이는 것을 특징으로 하는 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템.

청구항 7

제1항에 있어서,

상기 3D 객체 감지부(300)는,

증강된 포인트 클라우드(Augmented Point Cloud)를 입력받아 3D Sparse Convolution을 통해 조감도(Bird's Eye View, BEV)로 변환하고,

3D 객체를 감지하기 위한 3D Box Proposals을 생성하는 것을 특징으로 하는 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템.

청구항 8

제1항에 있어서,

상기 결과 출력부(400)는,

감지된 3D 객체의 위치 및 크기 정보를 시각화하며,

외부 시스템으로 데이터를 전송할 수 있는 인터페이스를 포함하는 것을 특징으로 하는 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템.

청구항 9

Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템을 이용한 방법에 있어서,

(a) 상기 3D 객체감지 성능향상 시스템이 카메라 이미지를 입력받아 Depth Map을 생성하고 이를 기반으로 Pseudo-LiDAR를 생성하며, 생성된 Pseudo-LiDAR의 포인트별 intensity 값을 거리 기반으로 정규화하고 로그 스케일로 재구성하는 단계,

(b) 상기 3D 객체감지 성능향상 시스템이 생성된 Pseudo-LiDAR와 LiDAR 데이터를 정량적으로 융합하고, 복셀로 변환된 포인트 클라우드의 밀도 정보를 비교한 후 부족 영역을 보완하여 증강된 포인트 클라우드를 생성함으로써, LiDAR의 거리 감쇠 및 탐지 누락을 보완하는 단계,

(c) 상기 3D 객체감지 성능향상 시스템이 복셀 기반 특징 추출과 포인트 기반 특징 복원을 결합한 증강된 포인트 클라우드를 학습된 PV-RCNN 딥러닝 모델에 입력함으로써, 원거리 탐지 정확도를 향상시키는 단계 및

(d) 상기 3D 객체감지 성능향상 시스템이 3D 객체 감지를 수행하는 단계를 포함하는 것을 특징으로 하는 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체 감지 성능 향상 방법.

발명의 설명

기술 분야

[0001]

본 발명은 3D 객체감지 성능향상 시스템에 관한 것이며, 보다 상세하게는 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템에 관한 것이다.

배경 기술

[0002] 자율주행 시스템에서의 객체 감지 성능은 차량의 주행 안정성에 핵심적인 요소로 작용하며, 이를 위해 고성능의 센서 융합 기법은 필수적이다. 현재 자율주행 기술에서는 주변 환경을 정밀하게 파악하기 위해 LiDAR(Light Detection and Ranging)와 카메라를 함께 사용하는 것이 일반적이다. LiDAR는 차량 주변의 거리 정보를 고해상도로 제공하지만, 데이터 밀도가 낮고 작은 객체나 먼 거리의 물체를 감지하는 데 한계가 있다. 반면 카메라는 텍스처와 색상 같은 시각적 정보를 풍부하게 제공하며, 특히 원거리 물체나 LiDAR가 놓치는 세부 정보까지 포함할 수 있다. 이러한 두 센서의 융합은 자율주행 시스템의 3D 객체 감지 성능을 향상하는 데 중요한 역할을 할 수 있다. 최신 센서 융합 방법들은 카메라 이미지에서 2D instance segmentation을 수행한 결과를 LiDAR 측에 융합하는 방법, LiDAR의 포인트 클라우드에서 3D instance segmentation을 수행 후 두 센서의 segmentation 결과를 융합하는 방법 등과 같이 두 센서의 장단점을 보완해 극대화하려는 방법이 제안되고 있다.

[0003] 최근에는 카메라 기반의 Pseudo-LiDAR 기술이 주목받고 있다. Pseudo-LiDAR는 카메라 이미지를 통해 depth 정보를 예측하여 생성되는 가상 포인트 클라우드로, 특히 원거리 또는 LiDAR로는 인식이 어려운 객체에 대한 정보를 제공하며 LiDAR의 약점을 보완하는 데 유리하다. 하지만 depth 측정 오차로 인해 생성된 데이터의 정확도가 낮을 수 있다. 이러한 카메라와 LiDAR 각 센서의 장단점은 센서 융합을 통해 서로의 단점을 보완하여 객체 감지 성능을 한층 더 개선할 수 있다. 카메라+LiDAR 융합 기법은 자율주행 연구의 중요한 주제로 자리 잡고 있으며, 다양한 연구들이 이를 개선하고 최적화하는 방향으로 발전하고 있다.

선행기술문헌

특허문헌

[0004] (특허문헌 0001) 특허공개 2024-0092382 (2024.06.24)

발명의 내용

해결하려는 과제

[0005] 본 발명은 LiDAR와 카메라 데이터를 융합하여 3D 객체 감지 성능을 향상시키는 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템 및 그 방법을 제공하는데 그 목적이 있다.

과제의 해결 수단

[0006] 본 발명에 따르면, 카메라 이미지를 입력받아 깊이 지도(Depth Map)를 생성하고 이를 기반으로 Pseudo-LiDAR를 생성하며, 생성된 Pseudo-LiDAR의 intensity를 로그 스케일로 재구성하는 Pseudo-LiDAR 생성부(100), 생성된 Pseudo-LiDAR와 LiDAR 데이터를 융합하여 증강된 포인트 클라우드를 생성하며, LiDAR의 한계를 보완하고 데이터 밀도를 높이는 포인트 클라우드 증강부(200), 증강된 포인트 클라우드를 학습된 PV-RCNN 딥러닝 모델에 입력하여 3D 객체 감지를 수행하는 3D 객체 감지부(300), 3D 객체 감지 결과를 시각화하거나 외부 시스템에 제공하는 결과 출력부(400)를 포함한다.

[0007] Pseudo-LiDAR 생성부(100)는 카메라 이미지로부터 생성된 깊이 지도(Depth Map)를 이용하여 각 픽셀의 3D 공간 좌표를 계산하며, 깊이 지도(Depth Map)와 픽셀 좌표를 기반으로 Pseudo-LiDAR를 생성하는 과정에서 좌표계와 데이터 정규화를 수행한다.

[0008] Pseudo-LiDAR 생성부(100)는 Pseudo-LiDAR의 반사 강도 값(intensity 값)을 거리 값에 따라 로그 스케일로 변환하여 근거리와 원거리 객체의 반사 강도의 차이를 반영한다.

[0009] 상기 포인트 클라우드 증강부(200)는 Pseudo-LiDAR와 LiDAR 데이터 간 좌표계 정규화 및 범위 정규화를 수행하고, 두 포인트 클라우드의 복셀 밀도를 비교하여 밀도가 낮은 영역을 보완하는 방식으로 증강된 포인트 클라우드를 생성한다.

[0010] 포인트 클라우드 증강부(200)는 Pseudo-LiDAR가 생성한 원거리 객체의 포인트 데이터를 LiDAR 포인트 클라우드의 부족한 영역에 추가하여 LiDAR의 감지 범위를 확장한다.

[0011] 3D 객체 감지부(300)는 복셀 기반(Voxel-based) 접근법과 포인트 기반(Point-based) 접근법을 결합한 PV-RCNN

딥러닝 모델을 사용하며, 복셀화(Voxelization)를 통해 데이터 처리량을 줄이고 계산 효율을 향상시키며, 포인트 단위 특징(Point-wise Feature) 학습을 통해 세부 정보를 복구하여 감지 정확도를 높인다.

[0012] 3D 객체 감지부(300)는 증강된 포인트 클라우드(Augmented Point Cloud)를 입력받아 3D Sparse Convolution을 통해 조감도(Bird's Eye View, BEV)로 변환하고, 3D 객체를 감지하기 위한 3D Box Proposals을 생성한다.

[0013] 결과 출력부(400)는 감지된 3D 객체의 위치 및 크기 정보를 시각화하며, 외부 시스템으로 데이터를 전송할 수 있는 인터페이스를 포함한다.

[0014] Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템을 이용한 방법에 있어서, (a) 상기 3D 객체감지 성능향상 시스템이 카메라 이미지를 입력받아 Depth Map을 생성하고 이를 기반으로 Pseudo-LiDAR를 생성하며, 생성된 Pseudo-LiDAR의 intensity를 로그 스케일로 재구성하는 단계, (b) 상기 3D 객체감지 성능향상 시스템이 생성된 Pseudo-LiDAR와 LiDAR 데이터를 융합하여 증강된 포인트 클라우드를 생성하며, LiDAR의 한계를 보완하고 데이터 밀도를 높이는 단계, (c) 상기 3D 객체감지 성능향상 시스템이 증강된 포인트 클라우드를 학습된 PV-RCNN 딥러닝 모델에 입력하는 단계 및 (d) 상기 3D 객체감지 성능향상 시스템이 3D 객체 감지를 수행하는 단계를 포함한다.

발명의 효과

[0015] 본 발명에 따르면, LiDAR와 Pseudo-LiDAR 데이터를 융합하여 3D 객체 감지 성능을 향상시키고, 딥러닝 모델(PV-RCNN)을 통해 효율적이고 신뢰성 있는 객체 감지를 가능하게 한다.

도면의 간단한 설명

[0016] 도 1은 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템의 구성도이다.

도 2는 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강 기법을 통한 3D 객체 감지 성능향상 시스템의 전체 개요도이다.

도 3은 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템에서 제안하는 3D 객체 감지 딥러닝 모델 학습 과정을 나타낸 것이다.

도 4는 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템의 카메라 이미지로 Pseudo-LiDAR 생성을 나타낸 것이다.

도 5는 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템의 Pseudo-LiDAR와 LiDAR 융합으로 포인트 클라우드 증강을 나타낸 것이다.

도 6은 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템의 PV-RCNN 모델 구조를 나타낸 것이다.

도 7은 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템의 Pseudo-LiDAR와 LiDAR 융합으로 증강된 포인트 클라우드의 3D 객체 감지 과정을 나타낸 것이다.

도 8은 제안된 방법의 실행과정 흐름도이다.

도 9는 본 발명에서 실험에 사용한 KITTI dataset 중 일부를 나타내고 있다.

도 10은 제안된 방법의 KITTI dataset 3D 인식 결과를 나타낸다.

발명을 실시하기 위한 구체적인 내용

[0017] 이하, 첨부 도면을 참조하여 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템을 설명하기로 한다.

[0018] 도 1은 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템의 구성도이다.

[0019] 도 1에 도시된 바와 같이, Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템(10)은 Pseudo-LiDAR 생성부(100), 포인트 클라우드 증강부(200), 3D 객체 감지부(300), 결과 출력부(400)를

포함한다.

- [0020] Pseudo-LiDAR 생성부(100)는 카메라 이미지를 입력받아 깊이 지도(Depth Map)를 생성하고 이를 기반으로 Pseudo-LiDAR를 생성하며, 생성된 Pseudo-LiDAR의 intensity를 로그 스케일로 재구성한다.
- [0021] 참고로, Intensity(강도 값)는 LiDAR 센서에서 레이저 빛이 물체에 반사되어 돌아온 신호의 세기를 나타내는 값이다. 이 값은 물체의 표면 특성과 거리, 반사율 등에 따라 달라지며, LiDAR 데이터를 통해 얻을 수 있는 중요한 속성 중 하나이다.
- [0022] Intensity의 특징과 역할은 다음과 같다.
- [0023] 첫째, Intensity는 반사율에 기반한 정보를 제공한다. Intensity는 물체 표면의 반사율에 따라 달라지며, 금속이나 유리처럼 고반사율 표면에서는 높은 intensity 값이 나타나고, 아스팔트나 나무 같은 저반사율 표면에서는 낮은 intensity 값이 나타난다.
- [0024] 둘째, Intensity는 거리와 관련된 정보를 제공한다. 가까운 물체에서는 강한 intensity 값이 나타나고, 먼 거리에서는 신호 세기가 약해져 낮은 intensity 값이 기록된다.
- [0025] 셋째, Intensity는 객체 분류와 감지 성능을 강화한다. Intensity 정보는 객체를 분류하고 감지하는 데 중요한 역할을 하며, 딥러닝 모델은 intensity 값을 활용하여 물체의 특성을 학습하고, 객체 감지 성능을 향상시킬 수 있다.
- [0026] 넷째, Pseudo-LiDAR에서 Intensity는 가상적으로 생성된 값을 의미한다. 실제 LiDAR와 달리, Pseudo-LiDAR는 카메라 데이터를 기반으로 생성되며, 본 발명에서는 거리를 기반으로 intensity를 로그 스케일로 재구성하여 현실성을 높인다.
- [0027] 따라서, Intensity는 LiDAR 데이터에서 반사율과 거리 정보를 나타내는 값으로, 물체의 특성을 식별하고 감지 성능을 강화하는 데 중요한 역할을 한다. Pseudo-LiDAR에서도 이 값을 재구성하여 실제 LiDAR 데이터와 유사한 특성을 반영하도록 한다.
- [0028] Pseudo-LiDAR 생성부(100)는 카메라 이미지로부터 생성된 깊이 지도(Depth Map)를 이용하여 각 픽셀의 3D 공간 좌표를 계산하며, 깊이 지도(Depth Map)와 픽셀 좌표를 기반으로 Pseudo-LiDAR를 생성하는 과정에서 좌표계와 데이터 정규화를 수행한다.
- [0029] 또한 Pseudo-LiDAR 생성부(100)는 Pseudo-LiDAR의 반사 강도 값(intensity 값)을 거리 값에 따라 로그 스케일로 변환하여 근거리와 원거리 객체의 반사 강도의 차이를 반영한다.
- [0030] 참고로, 반사 강도의 차이를 반영함에 있어서, 다음과 같은 의미를 가진다.
- [0031] 첫째, 근거리와 원거리의 반사 강도 차이를 명확히 표현한다. LiDAR 신호는 근거리에서는 강한 반사 강도를 나타내고, 원거리로 갈수록 반사 강도가 약해지는 특성을 가진다. 이러한 물리적 특성을 로그 스케일 변환을 통해 데이터에 반영하여, 근거리와 원거리 객체 간의 반사 강도 차이를 강조하거나 조정할 수 있도록 한다.
- [0032] 둘째, 가상 포인트 클라우드의 현실성을 향상시킨다. Pseudo-LiDAR는 카메라 기반으로 생성된 데이터로, 실제 LiDAR 데이터의 반사 강도 특성을 그대로 가지지 않는다. 로그 스케일 변환을 통해 실제 LiDAR 데이터에서 나타나는 반사 강도의 분포를 모방함으로써, 가상 포인트 클라우드(Pseudo-LiDAR)가 실제 LiDAR 데이터와 유사한 특성을 가지도록 만든다.
- [0033] 셋째, 객체 감지 모델의 학습 효과를 강화한다. 딥러닝 기반의 3D 객체 감지 모델은 입력 데이터의 특성을 학습하여 성능을 최적화한다. 반사 강도의 차이를 정확히 반영함으로써, 모델이 근거리와 원거리의 객체를 구별하고, 거리 정보와 관련된 패턴을 보다 효과적으로 학습할 수 있도록 돕는다.
- [0034] 넷째, 감지 성능을 개선한다. 반사 강도의 차이를 정확히 반영하면, 감지 성능이 떨어질 수 있는 원거리 객체나 저반사율 객체도 정확히 탐지할 수 있다. 이는 특히 복잡한 환경에서 객체의 경계와 특성을 보다 정확히 인식하는 데 기여한다.
- [0035] 따라서, '반사 강도의 차이를 정확히 반영한다'는 근거리와 원거리 객체의 반사 강도 분포를 명확히 구분하고, 현실감을 높이며, 객체 감지 성능을 강화하는 것을 의미한다. 이를 통해 학습 모델의 효율성과 정확성이 향상된다.
- [0036] 포인트 클라우드 증강부(200)는 생성된 Pseudo-LiDAR와 LiDAR 데이터를 융합하여 증강된 포인트 클라우드를 생

성하며, LiDAR의 한계를 보완하고 데이터 밀도를 높인다.

- [0037] 참고로, 카메라를 사용해 생성한 Pseudo-LiDAR 데이터와 LiDAR 센서를 통해 수집한 데이터를 가지고 있다고 가정한다. LiDAR 데이터는 가까운 객체에 대해 매우 정확한 정보를 제공하지만, 원거리 객체나 복잡한 환경에서는 데이터 밀도가 낮아질 수 있다. 반면, Pseudo-LiDAR 데이터는 카메라를 기반으로 생성되기 때문에 원거리 객체에 대한 정보를 포함하고 있지만, 근거리 데이터의 정확도가 LiDAR보다 떨어질 수 있다.
- [0038] 포인트 클라우드 증강부(200)는 이러한 두 데이터를 융합하여 두 센서의 단점을 보완하고, 밀도가 낮은 영역을 풍부하게 만든다. 예를 들어, LiDAR 데이터를 분석한 결과 원거리의 차량이 제대로 감지되지 않는다면, Pseudo-LiDAR 데이터를 사용해 해당 영역을 보완한다. 반대로, 근거리에서 Pseudo-LiDAR의 세부 정보가 부족한 경우 LiDAR 데이터를 활용하여 정확도를 높인다.
- [0039] 이 융합 과정을 통해 생성된 증강된 포인트 클라우드는 LiDAR와 Pseudo-LiDAR의 장점을 결합하여 근거리와 원거리 객체를 모두 포함한 균일한 밀도의 데이터를 제공한다.
- [0040] 이러한 포인트 클라우드 증강부(200)는 Pseudo-LiDAR와 LiDAR 데이터 간 좌표계 정규화 및 범위 정규화를 수행하고, 두 포인트 클라우드의 복셀 밀도를 비교하여 밀도가 낮은 영역을 보완하는 방식으로 증강된 포인트 클라우드를 생성한다.
- [0041] 참고로, 카메라를 이용해 생성한 Pseudo-LiDAR 데이터와 LiDAR 센서를 통해 수집한 데이터를 각각 확보했다고 가정한다. 이 두 데이터는 서로 다른 좌표계와 범위를 가지고 있어, 직접 결합할 수 없다. 따라서, 먼저 좌표계 정규화를 통해 두 데이터를 동일한 기준 좌표계로 변환하고, 범위 정규화를 통해 데이터의 크기와 범위를 일치시킨다. 예를 들어, Pseudo-LiDAR의 데이터가 카메라 중심 좌표계에 있다면, 이를 LiDAR의 센서 중심 좌표계로 변환한다.
- [0042] 그 다음, 두 포인트 클라우드 데이터를 복셀화(Voxelization)하여 격자 형태로 변환한 뒤, 복셀 밀도를 비교한다. 만약 LiDAR 데이터의 특정 영역에서 포인트 밀도가 낮다면, Pseudo-LiDAR 데이터를 사용해 해당 영역을 보완한다. 예를 들어, LiDAR는 차량 근처의 데이터는 정확하지만, 원거리 데이터가 부족할 수 있다. 이때, Pseudo-LiDAR 데이터를 추가하여 원거리 객체의 정보를 보완할 수 있다.
- [0043] 이 과정으로 생성된 증강된 포인트 클라우드는 보다 균일한 밀도를 가지며, 근거리와 원거리의 객체를 모두 정확히 표현할 수 있게 된다. 이러한 증강된 데이터는 딥러닝 모델의 입력으로 사용되어 3D 객체 감지 성능을 향상시킬 수 있다.
- [0044] 또한 포인트 클라우드 증강부(200)는 Pseudo-LiDAR가 생성한 원거리 객체의 포인트 데이터를 LiDAR 포인트 클라우드의 부족한 영역에 추가하여 LiDAR의 감지 범위를 확장한다.
- [0045] 참고로, LiDAR 센서를 사용하여 도로 주변의 데이터를 수집했다고 가정한다. LiDAR는 근거리 객체(예: 가까운 차량이나 보행자)에 대해서는 정확한 포인트 데이터를 제공하지만, 원거리 객체(예: 50m 이상 떨어진 차량이나 구조물)에 대해서는 포인트 밀도가 낮아지거나 감지하지 못할 수 있다. 반면, Pseudo-LiDAR는 카메라 기반으로 생성되며, 원거리 객체에 대한 정보를 제공할 수 있는 장점이 있다.
- [0046] 포인트 클라우드 증강부(200)는 Pseudo-LiDAR 데이터에서 원거리 객체의 포인트 데이터를 추출하여 LiDAR 데이터의 부족한 영역에 추가한다. 예를 들어, LiDAR 데이터가 원거리의 차량을 감지하지 못했을 경우, Pseudo-LiDAR 데이터를 사용해 해당 차량의 포인트 데이터를 보완한다. 이를 통해 원거리 객체의 위치와 크기를 더 명확하게 표현할 수 있다.
- [0047] 이 과정을 통해 LiDAR의 감지 범위를 확장하고, 증강된 포인트 클라우드는 근거리와 원거리 모두에서 균일하고 정확한 데이터를 제공하게 된다.
- [0048] 3D 객체 감지부(300)는 증강된 포인트 클라우드를 학습된 PV-RCNN 딥러닝 모델에 입력하여 3D 객체 감지를 수행한다.
- [0049] 자율주행차가 도로 위에서 차량, 보행자, 장애물과 같은 객체를 감지해야 한다고 가정한다. 이때 증강된 포인트 클라우드는 차량 주변의 환경을 3차원적으로 표현한 데이터로, 근거리와 원거리 객체를 포함하며 밀도가 균일하게 보정된 상태이다.
- [0050] 3D 객체 감지부(300)는 이 증강된 포인트 클라우드를 PV-RCNN 딥러닝 모델의 입력으로 제공한다. PV-RCNN 모델은 이 데이터를 처리하여 도로 위의 객체를 감지한다. 예를 들어, 모델은 포인트 클라우드 데이터를 분석하여

도로 위에 있는 차량의 위치, 크기, 방향을 3D 경계 상자(3D Bounding Box)로 나타낸다. 동시에 보행자와 같은 작은 객체나 도로 표지판과 같은 고정된 객체도 감지할 수 있다.

- [0051] 이러한 3D 객체 감지부(300)는 복셀 기반(Voxel-based) 접근법과 포인트 기반(Point-based) 접근법을 결합한 PV-RCNN 딥러닝 모델을 사용하며, 복셀화(Voxelization)를 통해 데이터 처리량을 줄이고 계산 효율을 향상시키며, 포인트 단위 특징(Point-wise Feature) 학습을 통해 세부 정보를 복구하여 감지 정확도를 높인다.
- [0052] 참고로, 자율주행차가 LiDAR 센서를 통해 도로의 포인트 클라우드 데이터를 수집한다고 가정한다. 이 데이터를 복셀 기반(Voxel-based) 접근법으로 복셀화(Voxelization)하여 3차원 공간을 작은 격자(복셀)로 나누고, 각 격자 안에 포함된 포인트를 요약한다. 복셀화 과정은 데이터 크기를 줄이고, 딥러닝 모델이 효율적으로 처리할 수 있도록 돕는다. 예를 들어, 도로 위에 흩어진 100만 개의 포인트를 격자로 나누어 10만 개로 줄일 수 있다.
- [0053] 그러나 복셀화된 데이터는 효율적이지만, 세부 정보를 잃을 수 있다. 이를 보완하기 위해 포인트 기반(Point-based) 접근법을 사용하여 복셀 내의 각 포인트를 개별적으로 분석하고 중요한 특징(예: 객체의 가장자리, 윤곽선)을 학습한다. 이 과정은 세부 정보를 복구하고, 복잡한 객체 구조를 정확히 감지할 수 있도록 돕는다. 예를 들어, 차량의 윤곽선이나 보행자의 팔, 다리와 같은 세부적인 형태를 식별할 수 있다.
- [0054] PV-RCNN 모델은 복셀 기반 접근법으로 데이터 처리량을 줄여 속도를 높이고, 포인트 기반 접근법으로 세부 정보를 복구하여 정확도를 높인다. 이 결합된 방식은 차량, 보행자, 도로 표지판 등 다양한 객체를 빠르고 정확하게 감지할 수 있게 한다. 예를 들어, 도로 위 차량과 보행자를 감지하고, 각각의 3D 위치와 크기를 계산하여 자율주행 시스템이 안전하게 주행하도록 돕는다.
- [0055] 따라서, 복셀 기반 접근법은 효율성을, 포인트 기반 접근법은 세부 정보를 제공하며, PV-RCNN 모델은 두 가지를 결합하여 복잡한 환경에서도 높은 정확도의 3D 객체 감지를 가능하게 한다.
- [0056] 또한 3D 객체 감지부(300)는 증강된 포인트 클라우드(Augmented Point Cloud)를 입력받아 3D Sparse Convolution을 통해 조감도(Bird's Eye View, BEV)로 변환하고, 3D 객체를 감지하기 위한 3D Box Proposals을 생성한다.
- [0057] 참고로, 3D Box Proposals는 3D 객체 감지에서 객체가 있을 가능성이 높은 영역을 나타내는 후보 상자이다. 이는 딥러닝 모델이 3차원 공간에서 특정 객체를 감지하기 위해 탐색해야 할 영역을 좁히는 데 사용된다.
- [0058] 3D Box Proposals의 주요 특징은 다음과 같다.
- [0059] 첫째, 3D 경계 상자(Bounding Box)는 3차원 공간에서의 객체 위치, 크기, 방향을 포함한 박스를 생성하며, 일반적으로 x,y,z 좌표, 폭(width), 높이(height), 길이(length), 회전각(yaw)으로 정의된다.
- [0060] 둘째, 후보 영역 제한을 통해 포인트 클라우드 전체를 탐색하는 대신, 객체가 있을 가능성이 높은 제한된 영역만 분석하여 계산 효율성을 높인다.
- [0061] 셋째, 다양한 크기와 방향의 상자를 생성하여 객체의 실제 형태와 공간적 배치를 반영하며, 차량, 사람, 장애물 등 서로 다른 객체 유형에 적합한 상자를 제안한다.
- [0062] 넷째, 딥러닝 모델의 입력 단계에서 3D Box Proposals은 모델이 보다 정교한 검출 과정을 수행하기 위해 필요한 초기 입력으로 사용된다. 모델은 이 후보 상자들을 세밀히 분석하여 최종적으로 객체를 분류하고 정확한 위치와 크기를 계산한다.
- [0063] 3D Box Proposals의 생성 과정은 다음과 같다.
- [0064] 먼저, 증강된 포인트 클라우드에서 중요한 특징을 추출하는 Feature Extraction 과정을 수행한다. 그다음, Region Proposal Network (RPN)를 활용하여 특징 맵을 기반으로 후보 상자를 생성한다. 마지막으로, Non-Maximum Suppression (NMS)을 통해 중복되거나 불필요한 상자를 제거하여 효율적인 후보 상자 집합을 남긴다.
- [0065] 따라서, 3D Box Proposals는 3D 객체 감지의 초기 단계에서 중요한 역할을 하며, 후보 영역을 효과적으로 정의하여 모델이 탐색 공간을 줄이고 감지 정확도를 높일 수 있도록 돕는다. 이는 자율주행 차량과 같은 시스템에서 객체를 빠르고 정확하게 탐지하는 데 필수적인 과정이다.
- [0066] 3D 객체 감지부의 작동원리를 간략히 설명하면 다음과 같다.
- [0067] 자율주행차가 LiDAR와 Pseudo-LiDAR 데이터를 융합하여 증강된 포인트 클라우드(Augmented Point Cloud)를 생성했다고 가정한다. 이 데이터는 차량 주변 환경의 3차원 정보를 포함하고 있다. 그러나, 이러한 3D 데이터를

바로 처리하기에는 계산량이 많기 때문에, 먼저 3D Sparse Convolution을 통해 데이터를 조감도(Bird's Eye View, BEV) 형태로 변환한다. 조감도는 3차원 데이터를 2차원 평면 위에 투영하여 객체의 위치와 크기를 보다 효율적으로 분석할 수 있도록 한다.

- [0068] 이 조감도를 기반으로 3D Box Proposals이 생성된다. 예를 들어, 도로 위의 차량, 보행자, 장애물 등의 후보 영역을 경계 상자(Bounding Box) 형태로 탐지한다. 이 단계에서는 포인트 클라우드의 밀도, 객체의 형태, 크기 등을 분석하여 객체가 있을 가능성이 높은 영역만 선별한다. 예를 들어, 차량 주변의 여러 포인트 클라우드에서 사각형 모양의 후보 상자를 생성하여 차량의 위치를 나타내고, 나머지 상자들은 보행자나 장애물의 위치를 나타낸다.
- [0069] 따라서, 3D 객체 감지부(300)는 증강된 포인트 클라우드를 효율적으로 처리하고, 조감도를 생성하여 객체 후보 영역(3D Box Proposals)을 탐지함으로써 3D 객체 감지를 가능하게 한다.
- [0070] 결과 출력부(400)는 3D 객체 감지 결과를 시각화하거나 외부 시스템에 제공한다. 이러한 결과 출력부(400)는 감지된 3D 객체의 위치 및 크기 정보를 시각화하며, 외부 시스템으로 데이터를 전송할 수 있는 인터페이스를 포함한다.
- [0071] 여기서, 외부 시스템은 3D 객체 감지 결과를 활용하는 다양한 응용 시스템을 의미한다.
- [0072] 첫째, 자율주행 시스템이다. 차량 주변의 객체(차량, 보행자, 장애물 등)를 감지한 결과를 자율주행 제어 시스템에 제공하여 경로 계획, 속도 조정, 충돌 방지와 같은 의사 결정을 지원한다.
- [0073] 둘째, 로봇 제어 시스템이다. 로봇이 주변 환경을 인식하고 경로를 결정하거나 작업을 수행할 때, 감지된 3D 객체 정보를 활용하여 효율적이고 안전한 동작을 가능하게 한다.
- [0074] 셋째, 감시 및 보안 시스템이다. 감지된 객체 정보를 보안 시스템에 전달하여 침입자 감지, 객체 추적, 이상 행동 탐지와 같은 기능을 수행한다.
- [0075] 넷째, 증강현실(AR) 및 가상현실(VR) 시스템이다. 감지된 객체 정보를 활용하여 3D 환경에 객체를 오버레이하거나, 가상 공간에서 실시간으로 객체와 상호작용할 수 있도록 한다.
- [0076] 다섯째, 산업 자동화 시스템이다. 공장에서 로봇 팔이나 자동화 장비가 3D 객체를 인식하고, 이를 기반으로 작업을 수행하거나 품질 검사를 진행할 수 있다.
- [0077] 따라서, 외부 시스템은 자율주행, 로봇 공학, 보안, AR/VR, 산업 자동화 등 감지된 3D 객체 데이터를 활용하여 다양한 기능을 수행하는 시스템을 의미한다.
- [0078] 참고로, 도로 위에서 3D 객체 감지를 수행했다고 가정한다. 예를 들어, 차량 주변의 차량, 보행자, 도로 표지판 등의 객체를 감지한 결과, 각각의 객체가 3D 공간에서 특정 위치와 크기를 가지고 있다고 판별된다.
- [0079] 결과 출력부(400)는 이러한 감지 결과를 시각적으로 표현한다. 예를 들어, 자율주행차의 화면에 감지된 객체들을 3D 경계 상자(Bounding Box)로 표시하고, 각 객체의 위치와 크기를 직관적으로 보여준다. 차량 주변의 다른 차량은 초록색 상자로, 보행자는 파란색 상자로 구분하여 표시할 수 있다. 이를 통해 운전자는 차량 주변 상황을 쉽게 이해할 수 있다.
- [0080] 또한, 결과 출력부(400)는 감지된 데이터를 외부 시스템에 전송하는 기능을 포함한다. 예를 들어, 감지된 3D 객체의 위치 및 크기 정보를 자율주행 제어 시스템으로 전달하여 차량의 속도 조정, 경로 변경, 장애물 회피 등의 의사 결정을 지원할 수 있다.
- [0081] 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템을 설명하면 다음과 같다.
- [0082] 본 발명에서 제안하는 Camera+LiDAR 기반의 포인트 클라우드 증강 기법을 통한 3D 객체 감지 성능 향상 방법의 독창성은 다음과 같다.
- [0083] 첫째, 기존의 정적 intensity 기반 Pseudo-LiDAR 방식에서 로그 스케일 방식을 통해 객체와 거리의 물리적 특성을 반영한 intensity로 재구성한다. 로그 스케일 방식의 intensity 재구성은 거리와 관련된 패턴을 포함하므로, 학습 모델이 공간적 구조와 객체 간의 거리 정보를 더 효과적으로 학습할 수 있게 되며, 객체가 겹쳐 있거나 복잡한 환경에서 성능 향상에 기여할 수 있다.
- [0084] 둘째, 기존의 단일 센서 또는 간단한 결합 방식에서 Camera+LiDAR 기반의 포인트 클라우드 증강 기법을 통한 센

서 융합 방식으로 대체한다. 카메라 기반의 Pseudo-LiDAR를 LiDAR의 약점을 보완하는 도구로 적극 활용하고, 이를 융합하여 데이터의 밀도와 세부 정보를 향상시켜 LiDAR의 낮은 해상도 문제와 원거리 객체 감지 한계를 보완할 수 있다.

- [0085] 본 발명에서 제안하는 Camera+LiDAR 기반의 포인트 클라우드 증강 기법을 통한 3D 객체 감지 성능 향상 시스템의 전체 개요도를 살펴보면, 도 2와 같다. 본 발명에서 제안하는 방법은 카메라 이미지를 이용하여 intensity가 재구성된 Pseudo-LiDAR를 획득하고 Pseudo-LiDAR와 LiDAR의 융합으로 포인트 클라우드를 증강한 후, 증강된 포인트 클라우드로 3D 객체 감지를 수행하는 시스템을 구축한다.
- [0086] 본 실시예에서 제안된 방법은 크게 3가지 과정으로 구성되며 각 과정은 카메라 이미지로 Pseudo-LiDAR 생성 및 intensity 재구성, Pseudo-LiDAR와 LiDAR 융합으로 포인트 클라우드 증강, 증강된 포인트 클라우드로 3D 객체 감지 딥러닝 모델 학습하는 과정으로 이루어진다.
- [0087] 먼저 첫 번째로, 카메라 이미지로 Pseudo-LiDAR 생성 및 intensity를 재구성한다. Pseudo-LiDAR는 카메라 이미지를 사용해 depth 정보를 추정하여 기존의 LiDAR 센서와 유사한 가상의 포인트 클라우드를 생성하는 방법이다.
- [0088] LiDAR는 포인트 클라우드를 제공하는 센서이기에 Pseudo-LiDAR로 생성된 가상의 포인트 클라우드는 실제 LiDAR와 결합할 때 각 센서의 장점을 극대화할 수 있다.
- [0089] 또한 intensity를 거리 값에 따라 로그 스케일로 변환하여 재구성하였다. 로그 스케일 방식은 LiDAR에서 가까운 객체가 더 강한 반사를 생성하는 특성을 모방하여, 가상 포인트 클라우드의 물리적 현실감을 높인다.
- [0090] 또한 원거리의 거리 값도 적절히 반영할 수 있도록 intensity를 부드럽게 조정하기 때문에 거리가 먼 객체가 감지되지 못하는 문제를 완화할 수 있다.
- [0091] 두 번째로, Pseudo-LiDAR와 LiDAR 융합으로 포인트 클라우드를 증강한다. 먼저 두 센서의 포인트 클라우드에 좌표계 및 범위 정규화를 수행하여 동일한 데이터 형식으로 변환한다. 그 후, 각 포인트 클라우드의 밀도를 복셀화하여 비교하고 LiDAR 포인트 클라우드에서 밀도가 적은 복셀을 보완하는 방식으로 융합을 진행한다. Pseudo-LiDAR는 카메라 기반으로 생성되므로 시야 범위가 더 넓어 원거리의 객체까지 포인트 클라우드가 생성되어 LiDAR의 거리적 스캔 한계를 보완할 수 있으며, 이를 통해 LiDAR의 낮은 해상도나 감지되지 않은 영역을 Pseudo-LiDAR 포인트로 채워 밀도를 높일 수 있다. 따라서, 융합된 포인트 클라우드는 더욱 균일한 밀도를 가지며, 3D 객체 감지 성능을 향상시킬 수 있다.
- [0092] 마지막으로 증강된 포인트 클라우드로 3D 객체 감지 딥러닝 모델을 학습한다. Pseudo-LiDAR와 LiDAR 융합으로 증강된 포인트 클라우드는 딥러닝 기반의 3D 객체 감지 모델의 입력으로 활용되며 학습된다. 본 발명에서는 Voxel-based 및 Point-based 네트워크 둘의 장점을 합친 PV(Point-Voxel)-RCNN 딥러닝 모델을 적용하여 3D 객체 감지의 학습을 진행하였다. Pseudo-LiDAR와 LiDAR 융합으로 증강된 포인트 클라우드는 더 많은 포인트와 다양한 특성을 제공하며, PV-RCNN 모델은 이를 효과적으로 활용할 수 있다. Voxelization 단계에서 데이터 밀도가 높아져 Voxel Feature Encoding의 성능이 향상되며, Point-wise feature 학습에서 Pseudo-LiDAR의 intensity 정보나 LiDAR의 정확한 거리 정보를 활용하여, 각 포인트의 특성을 세밀히 보완할 수 있다.
- [0093] 도 2는 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강 기법을 통한 3D 객체 감지 성능 향상 시스템의 전체 개요도이다.
- [0094] 본 발명에서는 카메라와 LiDAR 센서를 융합하여 생성된 포인트 클라우드를 증강함으로써 3D 객체 감지 성능을 향상시키는 시스템을 제안한다. 이를 위해 카메라 이미지로부터 Pseudo-LiDAR를 생성하고, LiDAR와 결합하여 포인트 클라우드 데이터를 강화한 후, 딥러닝 기반 3D 객체 감지 모델에 적용한다. 이러한 과정을 통해 기존 단일 센서의 한계를 보완하며, 특히 LiDAR의 낮은 해상도 및 원거리 객체 감지 문제를 효과적으로 해결한다.
- [0095] 본 발명에서 제안한 시스템의 과정은 다음과 같다.
- [0096] 첫째, 카메라 이미지로부터 Depth Map을 생성한다. 이는 Pseudo-LiDAR를 생성하기 위한 초기 단계로, 이미지의 2D 정보를 공간적 3D 정보로 변환하기 위한 기초 작업이다.
- [0097] 둘째, Depth Map을 활용하여 Pseudo-LiDAR 포인트 클라우드를 생성한다. 이 과정에서는 객체와 거리의 물리적 특성을 반영하기 위해 intensity 값을 로그 스케일로 변환하여 재구성한다. 이를 통해 현실감 있고 물리적 특성을 강화한 Pseudo-LiDAR 포인트 클라우드를 얻을 수 있다.
- [0098] 셋째, Pseudo-LiDAR와 LiDAR로부터 생성된 포인트 클라우드를 결합하여 증강된 포인트 클라우드를 생성한다. 이

를 위해 각 포인트 클라우드를 동일한 좌표계와 형식으로 정규화하고, 밀도 보완 방식을 적용하여 데이터의 균일성을 확보한다. 특히, Pseudo-LiDAR는 원거리 객체 정보를 보완하는 데 유리하여 LiDAR의 한계를 극복할 수 있다.

[0099] 넷째, 융합된 포인트 클라우드를 PV-RCNN 딥러닝 모델의 입력으로 활용하여 3D 객체 감지를 수행한다. 증강된 데이터는 더 높은 밀도와 다양한 특성을 제공하며, 이를 통해 학습된 모델은 복잡한 환경에서도 높은 객체 감지 성능을 발휘할 수 있다.

[0100] 본 발명에서 제안한 시스템은 효율적인 융합, 확장된 감지 범위, 학습 성능 향상과 같은 주요 장점을 제공한다. LiDAR와 Pseudo-LiDAR의 장점을 결합하여 데이터 밀도와 정확도를 높일 수 있으며, Pseudo-LiDAR의 원거리 객체 감지 능력을 활용하여 LiDAR의 단점을 보완할 수 있다. 또한, 딥러닝 모델이 증강된 데이터로 더 정교하고 다양한 객체를 감지할 수 있도록 지원한다.

[0101] 도 3은 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템에서 제안하는 3D 객체 감지 딥러닝 모델 학습 과정을 나타낸 것이다.

[0102] 본 발명의 학습 과정은 크게 3단계로 구성되며, 다음과 같은 과정을 통해 이루어진다.

[0103] ①카메라 이미지로 Pseudo-LiDAR 생성 및 intensity 재구성 단계에서, Pseudo-LiDAR는 카메라 이미지를 사용하여 Depth 정보를 추정된 뒤, 가상의 포인트 클라우드를 생성하는 방식이다.

[0104] 도 4는 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템의 카메라 이미지로 Pseudo-LiDAR 생성을 나타낸 것이다.

[0105] 도 4에서 볼 수 있듯이, 이 과정은 RGB 카메라 이미지를 기반으로 깊이 지도(Depth Map)를 생성하고, 이를 활용하여 Pseudo-LiDAR를 생성한다. LiDAR는 본래 포인트 클라우드를 제공하는 센서이지만, Pseudo-LiDAR는 저비용의 RGB 카메라를 활용하여 유사한 기능을 구현할 수 있는 장점이 있다. 이러한 방식은 LiDAR와 결합될 때 각 센서의 장점을 극대화할 수 있으며, 특히 원거리 물체 감지와 같은 특정 상황에서 LiDAR의 한계를 보완할 수 있다.

[0106] 본 발명은 Pseudo-LiDAR 생성 과정에서 intensity 값을 로그 스케일로 재구성하여 물체의 물리적 특성과 거리를 반영한다. 이를 통해 생성된 Pseudo-LiDAR는 LiDAR와 결합할 경우 데이터의 풍부함과 감지 성능을 향상시킬 수 있다.

[0107] 위와 같은 과정은 본 발명에서 제안하는 3D 객체 감지 딥러닝 모델 학습의 첫 번째 단계로, 이후 Pseudo-LiDAR와 LiDAR의 융합 및 증강된 데이터로 딥러닝 모델 학습을 진행한다. 이를 통해 더욱 정교하고 높은 성능의 3D 객체 감지 시스템을 구현할 수 있다.

[0108] 본 발명에서는 스테레오 매칭 기반의 깊이 지도(depth map)를 생성하여 각 픽셀의 depth를 추정하고, 이를 통해 가상의 포인트 클라우드인 Pseudo-LiDAR를 생성한다.

[0109] [수식1]

$$depth = \frac{f \cdot B}{disparity}$$

[0110]

[0111] 참고로, disparity는 PSMnet을 통해 계산되며, 이는 disparity 추정을 위해 삼 네트워크를 활용하여 스테레오 이미지에서 depth를 예측하는 스테레오 비전 접근 방식이다. PSMNet은 Pyramid Stereo Matching Network의 약자로, 스테레오 비전을 기반으로 깊이 정보를 추정하기 위해 설계된 딥러닝 기반 모델이다. 스테레오 이미지 쌍에서 disparity(시차)를 계산하고 이를 통해 depth(깊이)를 예측하는 데 사용된다.

[0112] PSMNet은 다중 해상도 피라미드 구조를 사용하여 다양한 규모와 멀티레벨 특징을 추출하는 것이 특징이다. 입력 이미지의 디테일뿐만 아니라 전체적인 구조적 정보를 효과적으로 캡처한다. 이 모델은 스테레오 이미지 쌍을 처리하기 위해 삼 네트워크(Siamese Network)를 활용하며, 동일한 가중치를 공유하는 두 신경망으로 좌측 이미지와 우측 이미지에서 특징을 추출하고 유사성을 비교한다.

[0113] PSMNet은 두 이미지 간의 disparity를 계산하기 위해 Cost Volume을 생성하며, 이는 서로 다른 disparity 값에 대해 두 이미지의 매칭 비용을 표현한 3차원 데이터이다. 이 Cost Volume을 학습하여 최적의 disparity를 추정

한다.

[0114] 또한 PSMNet은 Soft Attention Mechanism을 사용하여 중요한 특징에 집중하면서 깊이 예측의 정확도를 높인다. 이를 통해 텍스처가 적거나 유사한 패턴이 반복되는 영역에서도 정밀한 disparity 추정을 가능하게 한다.

[0115] disparity는 "시차"라고 할 수 있으며, 스테레오 비전에서 두 카메라로 촬영한 이미지 간에 대응되는 픽셀 간 위치 차이를 의미한다.

[0116] 쉽게 말해, 스테레오 카메라 시스템에서 같은 물체가 좌측 이미지와 우측 이미지에서 약간 다른 위치에 나타나며, 이 위치 차이를 "시차(disparity)"라고 한다.

[0117] 시차는 물체와 카메라 간의 거리와 밀접한 관련이 있으며, 이를 통해 깊이 정보를 계산할 수 있다. 예를 들어, 가까운 물체는 더 큰 시차를 보이고, 먼 물체는 작은 시차를 보인다. 스테레오 매칭 알고리즘은 이러한 시차를 계산하여 각 픽셀의 깊이(depth)를 추정하는 데 활용된다.

[0118] 스테레오 매칭 기반의 depth 추정은 [수식 1]과 같이 좌우 이미지 쌍의 disparity를 계산해 픽셀의 depth를 추정하며 여기서 f 는 초점거리, B 는 두 카메라 간의 베이스라인 거리를 의미한다.

[0119] 참고로, Depth Map은 이미지의 각 픽셀이 나타내는 점이 카메라로부터 얼마나 멀리 있는지(거리)를 나타내는 정보를 포함한 2차원 데이터이다. 일반적인 이미지가 밝기나 색상을 나타내는 반면, Depth Map은 공간적 깊이(depth) 정보를 표현한다.

[0120] Depth Map에서 각 픽셀 값은 카메라와 해당 픽셀이 나타내는 3D 공간의 점 사이의 거리(z 축)를 나타낸다. 픽셀 값이 작을수록 카메라에 가까운 물체를 나타내며, 픽셀 값이 클수록 먼 물체를 나타낸다.

[0121] Depth Map은 보통 흑백 이미지로 표현되며, 밝은 영역은 가까운 거리, 어두운 영역은 먼 거리를 나타낸다. 스테레오 카메라를 통해 얻어지는 두 이미지 간의 disparity(시차)를 기반으로 계산된다. 스테레오 매칭 알고리즘이나 딥러닝 모델(예: PSMNet)을 사용하여 계산된 disparity를 깊이 값으로 변환해 생성된다.

[0122] Depth Map은 2차원 평면에서 깊이 정보를 표현하지만, 이를 기반으로 3차원 공간의 포인트 클라우드를 생성할 수 있다. 각 픽셀의 깊이 값과 좌표를 변환해 3D 공간상의 점(x, y, z)으로 매핑된다. Depth Map은 충돌 방지, 거리 측정, 장애물 회피 등 다양한 거리 기반 응용에 사용된다. Depth Map 생성 과정은 스테레오 카메라로 촬영한 좌측 및 우측 이미지를 입력받아, 두 이미지의 대응되는 픽셀 간 위치 차이(disparity)를 계산하는 단계로 시작된다. 이후 disparity 값을 기반으로 깊이를 계산하는 수식을 적용해 각 픽셀의 깊이를 추정한다. 이 과정에서 카메라의 초점 거리(focal length)와 두 카메라 간 거리(baseline)가 사용된다.

[0123] [수식2]

$$z = depth(u, v)$$

$$x = \frac{(u - c_x) \cdot z}{f_x}, y = \frac{(v - c_y) \cdot z}{f_y}$$

[0124]

[0125] 여기서, z 는 해당 수식에서 픽셀의 깊이(Depth)를 나타내는 값이다. 이는 카메라 이미지의 픽셀(u, v)가 3차원 공간에서 얼마나 떨어져 있는지를 의미한다.

[0126] 구체적으로, z 는 이미지에서 특정 픽셀이 나타내는 점이 카메라 센서로부터의 거리(깊이)를 나타내며, Depth Map을 기반으로 계산된다. 이 값은 3D 좌표계의 x, y, z 좌표를 계산하는 데 필수적인 요소이다. 따라서, z 는 카메라를 중심으로 한 3D 공간에서 해당 픽셀이 위치한 깊이를 정의하는 중요한 변수이다.

[0127] 이렇게 생성된 depthmap과 이미지의 픽셀 좌표를 사용하여 각 픽셀을 3D 공간의 점으로 투영할 수 있으며, 이에 대한 식은 [수식 2]와 같다. 식에 따라 픽셀 좌표 (u, v)는 3D 좌표 (x, y, z)로 변환될 수 있으며 c_x, c_y 는 카메라 중심 좌표이며, f_x, f_y 는 카메라 렌즈의 초점거리를 나타낸다.

[0128] 이 수식을 통해 각 픽셀의 깊이 정보와 이미지 좌표를 기반으로 3D 공간 상의 정확한 위치를 계산할 수 있다. 본 변환 과정을 통해 이미지에서 얻어진 정보를 3차원 포인트 클라우드 형태로 표현할 수 있으며, 이는 Pseudo-LiDAR 생성 및 LiDAR와의 융합에 활용된다.

- [0129] 마지막으로 x, y, z 형태의 3D 좌표로 생성된 포인트 클라우드를 LiDAR 포맷과 유사한 x, y, z, intensity의 4차원 구조로 변환하게 된다.
- [0130] intensity는 레이저 빛이 물체에 반사된 강도를 나타내며, 주로 금속과 같은 고반사율 표면이나 근거리에서 1에 가까운 값을 나타내고 아스팔트 같은 저반사율 표면이나 원거리에서는 0에 가까운 값을 나타낸다.
- [0131] 기존 Pseudo-LiDAR는 보편적으로 intensity를 1 혹은 0으로 초기화하여 사용하게 된다. 하지만 이러한 동일 값의 초기화는 학습 모델이 intensity에 대한 추가적인 정보를 학습할 수 없고, 거리와의 상관관계가 없어진다.
- [0132] 본 발명에서는 intensity를 거리 값 z에 따라 로그 스케일로 변환하여 재구성하였으며 그 식은 [수식 3]과 같다.
- [0133] [수식 3]
- $$\text{intensity} = \log_{70}(70 - z)$$
- [0134]
- [0135] [수식 3]에서의 70은 최대 약 70m까지의 거리를 활용하려는 뜻이며, 약 70m 이상의 음수로 출력되는 값들은 0으로 처리하였다.
- [0136] 로그 스케일 방식은 LiDAR에서 가까운 객체가 더 강한 반사를 생성하는 특성을 모방하여, 가상 포인트 클라우드의 물리적 현실감을 높인다. 즉, 로그 스케일 방식은 LiDAR의 특성을 모방하여 가까운 객체가 더 강한 반사를 생성하도록 하며, 이로 인해 가상 포인트 클라우드의 물리적 현실감을 높인다.
- [0137] 또한 원거리의 거리 값도 적절히 반영할 수 있도록 intensity를 부드럽게 조정하기 때문에 거리가 먼 객체가 감지되지 못하는 문제를 완화할 수 있다.
- [0138] 따라서 본 실시예에서, 로그 스케일 방식의 intensity 재구성은 거리와 관련된 패턴을 포함하므로, 학습 모델이 공간적 구조와 객체 간의 거리 정보를 더 효과적으로 학습할 수 있게 된다. 이는 특히 객체가 겹쳐 있거나 복잡한 환경에서 성능 향상에 도움을 줄 수 있다.
- [0139] 도 5는 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템의 Pseudo-LiDAR와 LiDAR 융합으로 포인트 클라우드 증강을 나타낸 것이다.
- [0140] ② Pseudo-LiDAR와 LiDAR 융합으로 포인트 클라우드 증강과 관련하여, 본 발명에서는 도 4와 같이 Pseudo-LiDAR와 LiDAR를 효과적으로 결합하기 위해 데이터 레벨 융합(data-level fusion) 방식을 채택한다. Pseudo-LiDAR와 LiDAR는 기본적으로 서로 다른 방식으로 생성된 데이터이기 때문에, 먼저 두 센서의 포인트 클라우드에 대해 좌표계와 범위 정규화를 수행하여 동일한 데이터 형식으로 변환한다.
- [0141] 그 후, 각 포인트 클라우드의 밀도를 복셀화하여 비교하고, LiDAR 포인트 클라우드에서 밀도가 적은 복셀을 Pseudo-LiDAR의 데이터를 통해 보완하는 방식으로 융합을 진행한다. Pseudo-LiDAR는 카메라 기반으로 생성되기 때문에 시야 범위가 더 넓어 원거리 객체의 포인트 클라우드를 생성할 수 있다. 이를 통해 LiDAR의 거리적 스캔 한계를 효과적으로 보완하며, 낮은 해상도 문제나 감지되지 않은 영역을 Pseudo-LiDAR 포인트로 채워 데이터의 밀도를 높일 수 있다.
- [0142] 또한, Pseudo-LiDAR는 객체의 윤곽선과 같은 세부적인 3D 형상을 캡처할 수 있어, 학습 모델이 객체를 더욱 정확하게 인식할 수 있다. 따라서, 융합된 포인트 클라우드는 더욱 균일한 밀도를 가지며, 이는 3D 객체 감지 성능을 향상시킬 수 있다.
- [0143] 도 6은 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템의 PV-RCNN 모델 구조를 나타낸 것이다.
- [0144] ③ 증강된 포인트 클라우드로 3D 객체 감지 딥러닝 모델 학습과 관련하여,
- [0145] Pseudo-LiDAR와 LiDAR 융합으로 증강된 포인트 클라우드는 딥러닝 기반의 3D 객체 감지 모델의 입력으로 활용되며 학습된다.
- [0146] 본 발명에서는 Voxel-based 및 Point-based 네트워크 둘의 장점을 합친 PV(Point-Voxel)-RCNN 딥러닝 모델을 적용하여 3D 객체 감지의 학습을 진행하였다.
- [0147] Voxel-based 접근법은 융합된 포인트 클라우드를 격자 형태로 변환하여 모델 입력으로 사용하며, 객체의 구조적

특징을 포착하는 데 유리하다. 반면, Point-based 네트워크는 융합된 포인트 클라우드를 그대로 사용하여 객체의 세부 정보를 더욱 정밀하게 파악할 수 있다.

- [0148] PV-RCNN의 핵심은 Voxelization과 Point-wise Feature 학습의 결합이다. Voxel 방식은 희소 포인트 클라우드를 효율적으로 처리할 수 있지만, 세부 정보 손실 문제가 있다. 즉, PV-RCNN은 이 두 방식을 결합하여 Voxelization으로 계산량을 줄여 효율성을 극대화하고, Point-wise Feature 학습을 통해 미세 정보를 복구함으로써 정확성을 향상시켰다. 이러한 접근법은 대규모 데이터 처리의 효율성과 객체 감지의 정밀성을 모두 충족할 수 있다.
- [0149] Point-wise 방식은 개별 포인트의 세밀한 정보를 학습할 수 있으나, 계산량이 많아 대규모 데이터 처리에 비효율적이다. PV-RCNN은 이 둘을 결합하여 Voxelization을 통해 계산량을 줄여 효율성을 극대화 하고, Point-wise feature를 활용해 미세 정보를 복구하여 정확성을 높였다. PV-RCNN 모델의 구조는 도 5와 같다.
- [0150] Voxelization 단계에서는 3D Sparse Convolution을 통해 데이터를 BEV(Bird's Eye View)로 변환하고, 3D Box Proposals을 생성한다. 동시에, FPS(Farthest Point Sampling) 방법으로 Keypoints를 추출하여 Voxel Set Abstraction Module에서 특징을 추출한 후, Keypoints와 결합하여 최종적으로 3D 객체를 감지한다.
- [0151] 도 7은 본 발명의 일 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템의 Pseudo-LiDAR와 LiDAR 융합으로 증강된 포인트 클라우드의 3D 객체 감지 과정을 나타낸 것이다.
- [0152] Pseudo-LiDAR와 LiDAR 융합으로 증강된 포인트 클라우드는 더 많은 포인트와 다양한 특성을 제공하며, PV-RCNN 모델은 이러한 데이터를 효과적으로 활용할 수 있다. Voxelization 단계에서는 데이터 밀도가 높아져 Voxel Feature Encoding 성능이 향상되며, Point-wise Feature 학습에서는 Pseudo-LiDAR의 intensity 정보와 LiDAR의 정확한 거리 정보를 결합하여 각 포인트의 특성을 세밀히 보완한다.
- [0153] 이러한 과정을 통해 PV-RCNN 모델은 복잡한 환경에서도 더욱 정확한 3D 객체 감지가 가능해진다. 도 7은 Pseudo-LiDAR와 LiDAR를 융합하여 증강된 포인트 클라우드 데이터를 기반으로 3D 객체 감지 과정을 수행하는 모습을 나타낸다. 이 과정은 증강된 포인트 클라우드(Augmented Point Cloud) 데이터를 PV-RCNN 모델에 입력한 후, 최종적으로 3D Object Detection을 통해 객체를 감지하는 일련의 단계를 포함한다.
- [0154] 참고로, 3D Object Detection(3D 객체 감지)은 3차원 공간에서 객체를 식별하고, 해당 객체의 위치, 크기, 방향을 포함한 3D 정보를 추출하는 기술이다. 이는 주로 포인트 클라우드(Point Cloud)와 같은 3D 데이터를 입력으로 받아 이루어지며, 자율주행, 로봇 공학, 증강 현실(AR) 등 다양한 분야에서 중요한 역할을 한다.
- [0155] 객체 감지의 주요 요소는 다음과 같다.
- [0156] 첫째, 객체의 위치는 객체가 3차원 공간에서 어디에 존재하는지를 나타내며, 보통 x,y,z 좌표로 표현된다.
- [0157] 둘째, 크기는 객체의 가로, 세로, 높이를 포함하는 물리적 크기를 나타낸다.
- [0158] 셋째, 방향은 객체가 공간에서 어느 방향으로 향하고 있는지를 나타내며, 이는 자율주행에서 차량이나 도로 장애물의 방향을 인식하는 데 중요하다.
- [0159] 3D Object Detection의 단계는 다음과 같다.
- [0160] 첫째, 데이터 입력 단계에서 증강된 포인트 클라우드(Augmented Point Cloud) 또는 LiDAR 데이터와 같은 3D 데이터를 입력으로 받는다.
- [0161] 둘째, 객체 후보 영역 생성 단계에서 포인트 클라우드 데이터를 분석하여 객체가 있을 가능성이 높은 영역(3D BBox: 3D Bounding Box)을 탐지한다.
- [0162] 셋째, 객체 분류 및 위치 확정 단계에서 딥러닝 모델(PV-RCNN 등)이 후보 영역을 세부적으로 분석하여 객체를 분류(예: 차량, 사람 등)하고 정확한 위치, 크기, 방향을 예측한다.
- [0163] 넷째, 출력 단계에서 탐지된 3D 객체의 정보를 시각화하거나, 필요한 경우 외부 시스템(예: 자율주행차 제어 시스템)에 전달한다.
- [0164] 예를 들어, 자율주행차의 3D 객체 감지 시스템은 도로 위 차량, 보행자, 장애물 등을 감지하고 이들의 3D 위치와 크기를 인식하여 충돌 방지나 경로 계획을 수행할 수 있다. 3D Object Detection은 2D 이미지 기반 객체 감지와 달리, 깊이와 위치 정보를 포함하여 환경을 더 정확하고 세밀하게 이해할 수 있는 점에서 강력한

도구이다.

[0165] 본 실시예에 따른 Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템의 실행 과정은 학습 과정에서 학습된 PV-RCNN 딥러닝 모델을 이용하여 수행된다.

[0166] 도 8은 제안된 방법의 실행과정 흐름도이다.

[0167] 도 8에 도시된 바와 같이, Camera+LiDAR 기반의 포인트 클라우드 증강기법을 통한 3D 객체감지 성능향상 시스템(이하, 3D 객체감지 성능향상 시스템이라 함)을 이용한 방법에 있어서, (a) 3D 객체감지 성능향상 시스템은 카메라 이미지를 입력받아 깊이 지도(Depth Map)를 생성하고 이를 기반으로 Pseudo-LiDAR를 생성하며, 생성된 Pseudo-LiDAR의 intensity를 로그 스케일로 재구성한다.

[0168] 다음으로 (b) 3D 객체감지 성능향상 시스템은 생성된 Pseudo-LiDAR와 LiDAR 데이터를 융합하여 증강된 포인트 클라우드를 생성하며, LiDAR의 한계를 보완하고 데이터 밀도를 높인다.

[0169] 다음으로 (c) 3D 객체감지 성능향상 시스템은 증강된 포인트 클라우드를 학습된 PV-RCNN 딥러닝 모델에 입력한다.

[0170] 그리고 (d) 3D 객체감지 성능향상 시스템은 3D 객체 감지를 수행하는 단계를 포함한다.

[0171] 실행과정에서는 학습 과정에서 학습된 PV-RCNN 딥러닝 모델을 이용하여 카메라 이미지로부터 intensity가 재구성된 Pseudo-LiDAR를 획득하고 Pseudo-LiDAR와 LiDAR의 융합으로 포인트 클라우드를 증강한 후, 증강된 포인트 클라우드를 PV-RCNN의 입력에 넣어 출력되는 출력 값을 통해 3D 객체 감지를 수행한다.

[0172] 본 실시예에 따른 실험환경은 다음과 같다.

[0173] 하드웨어는 Intel Xeon(R) Silver 4215R CPU, Nvidia RTX 3090(V-RAM 24GB) 4개 GPU, RAM 128GB. 운영체제는 Ubuntu 20.04 OS. 개발도구는 Visual Studio Code, Python 3.8. 라이브러리는 Pytorch 1.12.1, CUDA 11.3, MMDetection3D 1.4.0.

[0174] 데이터 셋과 관련하여, 3D 객체 감지의 학습 및 테스트에는 KITTI dataset을 사용하였다. 실험의 경우 train set을 3,712개의 train samples과 3,769개의 validation samples로 나눈 후 학습은 Epoch 40으로 동일하게 설정하여 학습하였고, 테스트는 validation samples로 진행하였다. 3D 객체 감지 딥러닝 모델은 PV-RCNN 모델을 기반으로 하였다. Car 클래스의 경우 IoU는 0.7, Pedestrian과 Cyclist 클래스는 IoU 0.5로 고정하고 AP 11 측정 항목과 Moderate 기준으로 테스트를 진행하였다. 측정된 mAP는 5번 반복된 실험을 통한 평균값이다. 도 9는 본 발명에서 실험에 사용한 KITTI dataset 중 일부를 나타내고 있다.

[0175] 실험 결과와 관련하여, 본 발명에서 제안한 Camera+LiDAR 기반의 포인트 클라우드 증강 기법을 통한 3D 객체 감지 성능 향상에 대한 실험 결과는 [표 1]과 같다. [표 1]은 기존 기법들과의 3D 객체 감지 성능 비교 결과를 나타낸다.

[0176] [표 1]

No	Method	mAP ↑
1	MVX-Net	63.5
2	Part-A2	68.33
3	PV-RCNN	72.28
4	Pseudo-LiDAR(intensity:1) + LiDAR + PV-RCNN	72.5
5	The proposed method(intensity : log scale)	72.65

[0177]


[0178] MVX-Net은 LiDAR와 카메라 데이터 융합을 활용한 3D 객체 감지의 기초 모델로 LiDAR의 정확한 거리 정보와 카메라의 풍부한 RGB 정보를 Early Fusion 방식으로 결합하여, 객체 감지 성능을 향상 시켰다. Part-A2는 포인트 클라우드의 구조적 특징을 활용해 객체 감지 성능을 향상시켰다. 이 모델은 객체의 Parts 정보를 추출하고 이를 효율적으로 집계하여, 전체 객체 수준의 특징을 강화하여 기존 방식보다 복잡한 구조를 가진 객체도 정확히 감

지가 가능하다. 또한 intensity를 로그 스케일로 변환하여 재구성하는 방식의 정량적 평가를 위해 intensity를 1로 초기화하여 Pseudo-LiDAR를 생성한 경우의 실험도 진행하였다.


- [0179] 실험 결과, 본 발명에서 제안한 Camera+LiDAR 기반의 포인트 클라우드 증강 기법을 통한 3D 객체감지의 성능이 기존의 방법들보다 우수한 성능을 나타내었다. 특히 학습 모델로 쓰였던 PV-RCNN과 비교하여 mAP가 약 0.37 증가하였다. Pseudo-LiDAR와 LiDAR 융합으로 증강된 포인트 클라우드는 Voxel Feature Encoding 단계에서 더 다양한 공간 정보를 제공하기에 모델이 더 나은 물체 후보를 생성한 것으로 예상된다. 또한 멀리 있는 객체에서 희소성이 문제가 되는 LiDAR의 한계를 Pseudo-LiDAR가 보완한 것으로 예상된다. intensity를 1로 초기화하여 Pseudo-LiDAR를 생성한 경우 고정된 intensity 값으로 인해 객체 간의 세밀한 차이를 학습하기 어렵고 거리와의 상관관계가 없어진다. 이에 따라 상대적으로 단순한 환경에서는 성능 차이가 크지 않을 수 있으나, 복잡한 환경에 대해 성능이 저하된 것으로 예상된다. 도 10은 제안된 방법의 KITTI dataset 3D 인식 결과를 나타낸다.
- [0180] 본 발명에서는 카메라+LiDAR 기반의 포인트 클라우드 증강 기법을 통해 3D 객체 감지 성능을 향상하는 방법을 제안하였다.
- [0181] 제안한 기법은 기존의 방식과 다른 다음과 같은 독창성이 있다.
- [0182] 첫 번째, 기존의 정적 intensity 기반 Pseudo-LiDAR 방식에서 로그 스케일 방식을 통해 객체와 거리의 물리적 특성을 반영한 intensity로 재구성한다.
- [0183] 로그 스케일 방식의 intensity 재구성은 거리와 관련된 패턴을 포함하므로, 학습 모델이 공간적 구조와 객체 간의 거리 정보를 더 효과적으로 학습할 수 있게 되어, 객체가 겹쳐 있거나 복잡한 환경에서 성능 향상에 기여할 수 있다.
- [0184] 두 번째, 기존의 단일 센서 또는 간단한 결합 방식에서 Camera+LiDAR 기반의 포인트 클라우드 증강 기법을 통한 센서 융합 방식으로 대체한다. 카메라 기반의 Pseudo-LiDAR를 LiDAR의 약점을 보완하는 도구로 적극 활용하고, 이를 융합하여 데이터의 밀도와 세부 정보를 향상시켜 LiDAR의 낮은 해상도 문제와 원거리 객체 감지 한계를 보완할 수 있다.
- [0185] 제안하는 기법의 수행 과정은 다음과 같다.
- [0186] 첫 번째로, 카메라 이미지로 Pseudo-LiDAR 생성 및 intensity 재구성을 수행한다. Pseudo-LiDAR는 LiDAR가 감지하기 어려운 원거리의 객체나, 작은 물체의 세부 정보를 보완할 수 있다.
- [0187] 또한 로그 스케일 방식의 intensity 재구성은 거리와 관련된 패턴을 포함하므로, 학습 모델이 공간적 구조와 객체 간의 거리 정보를 더 효과적으로 학습할 수 있도록 한다.
- [0188] 두 번째로, Pseudo-LiDAR와 LiDAR 융합으로 포인트 클라우드 증강한다. 이를 통해 LiDAR의 낮은 해상도나 감지되지 않은 영역을 Pseudo-LiDAR 포인트로 채워 밀도를 높이고, 객체의 윤곽선을 명확하게 표현할 수 있다.
- [0189] 마지막으로, 증강된 포인트 클라우드로 3D 객체 감지 딥러닝 모델 학습한다. 증강된 포인트 클라우드는 더 많은 포인트와 다양한 특성을 제공하며, PV-RCNN 모델은 이를 효과적으로 활용할 수 있다. 제안하는 기법의 객관적인 신뢰성을 평가하기 위해 KITTI dataset으로 다른 딥러닝 모델들과 mAP를 산출하여 성능을 비교하였다.
- [0190] 실험 결과, 본 실시예에서 제안한 Camera+LiDAR 기반의 포인트 클라우드 증강 기법을 통한 3D 객체 감지의 성능이 기존의 방법들보다 우수한 성능을 나타내었다. 특히 학습 모델로 쓰였던 PV-RCNN과 비교하여 mAP가 약 0.37 증가하였다. 실험에서 우수한 결과를 나타내므로 본 실시예에서 제안한 기법의 효율성이 입증되었다.

도면

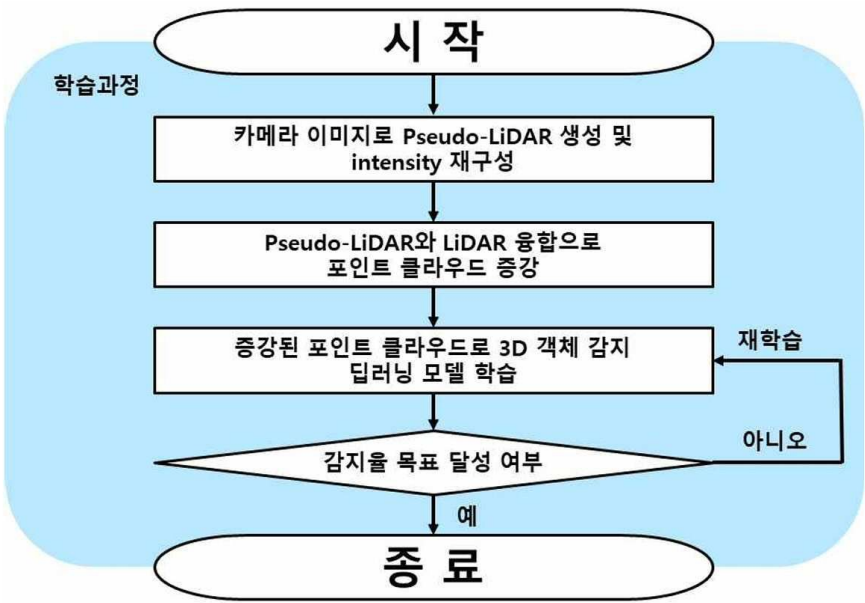
도면1




도면2




도면3




도면4




도면5




도면6



도면7



도면8



도면9



도면10

