

Two-bounce LiDAR Digital Twin based data generation framework for object detection in the blind spot

Jae-Hun Hwang*,**, Seung Yeop Ha***, Jun-Seok Yun****, Min Su Kim*****,
Sanga Lee*****, Jong Pil Yun*****, Hong-In Won*****

*M.S. Student, Manufacturing AI Research Center, Korea Institute of Industrial Technology, Incheon, Korea

**M.S. Student, Dept. of Artificial Intelligence Convergence, Hanyang University, Seoul, Korea

***Integrated M.S./Ph.D. Student, Manufacturing AI Research Center, Korea Institute of Industrial Technology,
Incheon, Korea

****Researcher, Manufacturing AI Research Center, Korea Institute of Industrial Technology, Incheon, Korea

*****Senior Researcher, Manufacturing AI Research Center, Korea Institute of Industrial Technology,
Incheon, Korea

*****Principal Researcher, Manufacturing AI Research Center, Korea Institute of Industrial Technology,
Incheon, Korea

[Abstract]

Obstacle detection in blind spots has emerged as a critical challenge due to the increasing adoption of Automated Guided Vehicle (AGV) and Autonomous Mobile Robot (AMR) systems in modern industrial environments. While conventional ultrasonic and single-bounce LiDAR sensors exhibit limitations in complex environments, Two-Bounce LiDAR offers higher detection precision but faces challenges such as high cost and limited diversity in training data. To address these challenge, this study proposes a framework that combines Two-Bounce LiDAR with Digital Twin simulation to generate synthetic data under various scenarios. Object detection models trained with this data achieved an average detection accuracy of 92.5% in environments including blind spots, with an average improvement of 14.67 percentage points in accuracy and 15.69 points in F1-score compared to models trained only on normal-environment data. These findings demonstrate that the proposed framework effectively overcomes data collection limitations and significantly enhances the safety and reliability of AGV and AMR operations.

▶ **Key words:** Digital Twin, Data generation, Two-Bounce LiDAR, Blind spot, Object detection

-
- First Author: Jae-Hun Hwang, Corresponding Author: Hong-In Won
 - **Jae-Hun Hwang (jv29734v@kitech.re.kr), Manufacturing AI Research Center, Korea Institute of Industrial Technology, Dept. of Artificial Intelligence Convergence, Hanyang University
 - **Seung Yeop Ha (chris257@kitech.re.kr), Manufacturing AI Research Center, Korea Institute of Industrial Technology
 - ***Jun-Seok Yun (yunjs@kitech.re.kr), Manufacturing AI Research Center, Korea Institute of Industrial Technology
 - ****Min Su Kim (kms6777@kitech.re.kr), Manufacturing AI Research Center, Korea Institute of Industrial Technology
 - *****Sanga Lee (ivory@kitech.re.kr), Manufacturing AI Research Center, Korea Institute of Industrial Technology
 - *****Jong Pil Yun (rebirth@kitech.re.kr), Manufacturing AI Research Center, Korea Institute of Industrial Technology
 - *****Hong-In Won (luvhaym@kitech.re.kr), Manufacturing AI Research Center, Korea Institute of Industrial Technology
 - Received: 2025. 05. 07, Revised: 2025. 05. 29, Accepted: 2025. 05. 29.

[요 약]

현대 제조 환경에서 Automated Guided Vehicle (AGV) 및 Autonomous Mobile Robot (AMR) 의 확산에 따라 사각지대 내 장애물 탐지가 작업 안전의 핵심 과제로 부상하고 있다. 기존 초음파 및 단일 반사 기반 LiDAR는 사각지대에서 탐지 한계가 존재하며, Two-Bounce LiDAR는 대안으로 주목받지만 고비용 및 환경 민감성으로 인해 대규모 학습 데이터 확보에 어려움이 있다. 본 연구는 Two-Bounce LiDAR와 디지털 트윈 시뮬레이션을 결합한 데이터 생성 프레임워크를 제안한다. 제안된 프레임워크를 통해 다양한 시나리오를 시뮬레이션해 생성한 데이터를 활용하여 객체 탐지 모델을 학습한 결과, 사각지대 포함 환경에서 평균 92.5% 탐지 정확도를 달성하였고, 기존 방식 대비 평균 정확도는 14.67%p, F1-score는 15.69%p 향상되었다. 이는 제안된 프레임워크가 데이터 수집의 한계를 극복하고 AGV/AMR 운용의 안전성과 신뢰성을 높일 수 있음을 시사한다.

▶ **주제어:** 디지털 트윈, 데이터 생성, 투 바운스 라이다, 사각지대, 객체 탐지

I. Introduction

최근 제조업 및 물류 산업 등 다양한 산업 현장에서 AGV와 AMR의 활용이 급격히 증가함에 따라, 이들의 운용 중에 발생할 수 있는 사각지대 문제가 작업 안전성과 운영 효율성 측면에서 중요한 이슈로 부각되고 있다 [1]. 사각지대란 센서가 구조물이나 물체에 가려져 감지하지 못하는 영역으로, 좁은 통로와 다양한 크기의 장애물이 혼재하는 산업 환경에서는 충돌 사고의 주요 원인이 된다 [2]. 특히 물류 창고나 제조 현장에서 팔레트, 박스, 기타 작업 도구 등이 Fig. 1과 같은 사각지대를 형성하며, AGV나 AMR이 이러한 구역을 통과할 때 장애물을 인식하지 못해 장비 손상 및 작업자 사고로 이어질 수 있다 [3].




Fig. 1. Blind Spot in Industrial Sites

이를 해결하기 위해 초음파 센서, LiDAR 등 다양한 센서 기반 객체 감지 기술이 개발되어 왔다. 초음파 센서는 저비용과 빠른 반응 속도를 제공하지만, 복잡한 산업 환경에서는 반사 및 산란으로 인한 감지 오류가 빈번히 발생한다 [4, 5]. LiDAR는 고정밀 3D 공간 정보를 제공하여 상대적으로 정확도가 높지만, 대부분 첫 번째 반사 신호만을

분석하기 때문에 사각지대 뒤편에 있는 객체를 탐지하는데 한계가 있다 [6, 7].

이러한 기술적 제약을 극복하기 위한 대안으로 최근 Single-Photon Avalanche Diode (SPAD) 기반 Two-Bounce LiDAR가 연구되고 있다. Two-Bounce LiDAR는 첫 번째 반사뿐 아니라 두 번째 반사 신호까지 분석하여 기존 센서로는 관측할 수 없었던 사각지대 내 객체를 감지할 가능성을 제시한다 [6]. 그러나 SPAD 기반 고감도 LiDAR 센서는 높은 가격과 환경 민감성으로 인해 실 환경에서 양질의 데이터를 확보하기 어렵다. 이는 AI 기반 객체 감지 모델 학습에도 제약을 초래하며, 충분한 시나리오 학습이 이루어지지 않아 학습되지 않은 반사 패턴이나 장애물이 나타났을 때 감지 실패 가능성이 증가하는 문제를 야기한다 [8].

이에 본 연구에서는 디지털 트윈 기반의 시뮬레이션 환경을 구축하여 다양한 조건에서 Two-Bounce LiDAR 데이터를 생성하고, 이를 AI 기반 장애물 감지 모델의 학습에 활용하는 프레임워크를 제안한다. 본 프레임워크는 복잡한 산업 환경에서 실제 데이터 수집의 한계를 극복하며, 사각지대 내 객체 감지 성능을 극대화할 수 있는 새로운 접근 방식을 제공한다. 이를 통해 AGV 및 AMR의 운용 안전성 향상과 더불어 전체 산업 시스템의 신뢰성을 높이는 데 기여할 것으로 기대된다.

II. Related Works

1. Digital Twin-Based AI Learning

디지털 트윈 기술은 물리적 환경의 정밀한 가상화를 통해, 실제 데이터 수집이 어려운 조건에서도 다양한 형태의 학습 데이터를 생성할 수 있는 수단으로 널리 활용되고 있다[9, 10]. 특히 자율주행, 스마트 제조, 로봇 제어 등의 분야에서는 시뮬레이션 기반으로 다양한 장애물 조건, 속도 변화, 구조물 배치 등의 상황을 재현하여 AI 학습에 필요한 데이터셋을 구축하고 있다[11]. 이러한 방식은 학습 데이터의 다양성과 확장성을 확보할 수 있다는 점에서 중요한 이점을 제공한다.

예를 들어 CARLA 시뮬레이터는 자율주행 차량 연구에서 널리 사용되며, 다양한 날씨, 시간대, 교통 밀도 조건을 설정할 수 있어 객체 탐지 및 추적 알고리즘의 학습에 활용되고 있다 [12]. 또한, AirSim은 드론 및 지상 차량용 시뮬레이션을 제공하며, 고정밀 센서 데이터 (LiDAR, Depth, Segmentation 등)를 생성할 수 있는 환경을 구축한다 [13]. 제조 분야에서는 Siemens와 GE에서 디지털 트윈을 활용하여 설비 이상 예지 및 공정 최적화에 AI 모델을 적용한 바 있으며, 이는 물리 기반 시뮬레이션과 데이터 기반 학습을 효과적으로 결합한 사례로 평가된다 [14, 15].

이러한 연구들은 고위험 환경이나 실시간 데이터 확보가 어려운 조건에서 특히 유효하며, 다양한 시나리오를 설계하고 반복 실험할 수 있다는 장점으로 인해 AI 시스템의 신뢰성과 일반화 능력을 높이는 데 기여하고 있다.

2. Blind Spot Reconstruction via Two-Bounce LiDAR

직접 관측이 불가능한 사각지대 영역에서의 객체 탐지나 복원 문제를 해결하기 위한 연구로, 간접 반사 정보를 활용한 접근이 최근 주목받고 있다. 이러한 기술은 반사된 신호의 경로를 역추적함으로써 장애물 뒤편에 있는 객체의 존재 여부나 형상 정보를 추론할 수 있게 하며, 특히 LiDAR의 반사 특성을 활용한 방식이 실험적으로 활발히 검증되고 있다[6, 16].

이와 관련하여 최근 제안된 PlatoNeRF는 Two-Bounce LiDAR 데이터를 입력으로 활용하여 사각지대 내에 보이지 않는 객체의 3차원 형상을 복원하는 Neural Radiance Fields (NeRF) 기반의 모델로 주목받고 있다. 해당 모델은 간접 반사 경로에서 수집된 신호를 기반으로 시야 밖 객체의 위치와 형상을 예측하며, 기존

NeRF가 직접 관측된 시야에 한정되어 있던 한계를 극복한 사례로 평가된다 [6]. PlatoNeRF는 실내 및 복잡한 구조 환경에서도 활용 가능성이 크며, 사각지대 인지 기술의 정밀도를 획기적으로 개선할 수 있는 잠재력을 지닌다.

본 연구는 이러한 간접 반사 기반 복원 기법과는 달리, 객체 복원보다는 객체 감지 성능 향상에 초점을 맞추고 있다. Two-Bounce LiDAR 데이터를 다중 투영 이미지 형태로 변환하고, 이를 경량화된 AI 모델 학습에 활용함으로써 사각지대 객체 인식의 실시간성과 정확도를 동시에 확보하였다. 디지털 트윈을 활용한 다양한 시나리오의 반사 데이터를 효과적으로 생성함으로써, 실제 환경에 대한 일반화 성능 향상도 함께 기대할 수 있다.

III. The Proposed Scheme

본 절에서는 제안하는 Two-Bounce LiDAR 디지털 트윈 및 데이터 생성 프레임워크에 대해 설명한다. 1절에서는 Two-Bounce LiDAR 디지털 트윈 설계와 구현 방식을, 2절에서는 데이터 생성 시스템의 구성과 학습 데이터 구축 방법을 각각 다룬다.

1. Two-Bounce LiDAR Digital Twin

본 연구에서는 다중 반사 신호의 장점을 유지하면서도 데이터 처리 효율성과 구현 가능성을 확보하기 위해, SPAD 기반 Two-Bounce LiDAR 센서를 디지털 트윈 환경에서 구현하였다.

디지털 트윈을 통해 구현한 Two-Bounce LiDAR의 원리는 다음과 같다. 첫 번째로, 레이저 펄스가 발사되어 첫 번째 물체에 반사된 후, 주변 환경으로 산란되어 다른 물체에 도달한다. 두 번째 반사 신호는 다시 센서로 돌아와 분석되며, 이때 감지되는 Two bounce ray와 물체에 가려져 Two bounce ray 데이터가 취득되지 않는 영역인 Object Shadow의 데이터를 통해 장애물 뒤에 있는 물체의 거리와 형상을 감지할 수 있다. 이러한 기술은 좁은 통로, 장애물에 시야가 제한된 환경에서 매우 효과적이다.

1.1 Digital Twin Design for Two-Bounce LiDAR

Two-Bounce LiDAR를 디지털 트윈 환경에서 구현하기 위해 SPAD LiDAR 센서를 기반으로 디지털 트윈 모델을 설계했다 [6, 17]. 이 과정에서 실제 SPAD LiDAR 센서의 성능과 물리적 특성을 최대한 반영하기 위해 Table 1에 제시된 장비 정보를 기반으로 센서의 감지 범위, 레이




Fig. 2. Two-bounce LiDAR Digital Twin

저 펄스 분산 각도, 반사율 등 주요 물리적 특성을 디지털 트윈 모델에 적용하여 Fig. 2와 같이 구현했다.

를 효과적으로 수집할 수 있도록 하였다.

Table 1. Information about SPAD LiDAR

Specification	Details
Sensor Type	SPAD Direct ToF
Distance Resolution	15 cm
Time Resolution	128 picoseconds (ps)
Max Range	Up to 300 m
Spatial Resolution	512×512

또한 장애물 및 반사면의 위치, 재질, 반사율 등 다양한 물리적 변수를 조정할 수 있도록 시뮬레이션을 구성하여 다양한 반사 조건에서 발생하는 포인트 클라우드 데이터

1.2 Two-Bounce LiDAR Data Generation System

Two-Bounce LiDAR 디지털 트윈을 구현하기 위해 Ray-casting 라이브러리를 지원하는 Unity 엔진을 활용했다. Unity 엔진은 실시간 물리 엔진과 그래픽 처리 기능을 제공하며, Ray-casting 라이브러리를 통해 빛과 물체 간의 충돌을 Fig. 3과 같이 시뮬레이션할 수 있다. 이를 기반으로 SPAD LiDAR센서의 위치, 레이저 펄스 발사 방향을 입력받아 발생하는 Two-Bounce Ray의 확산과 경로 추적 함수를 설계하고 코드로 구현하였다.

SPAD LiDAR 센서의 반사 특성에 따른 확산과 경로를 추적하기 위해 본 논문에서는 반사 경로를 두 부분으로 구




Fig. 3. Two-bounce LiDAR Data Generate System

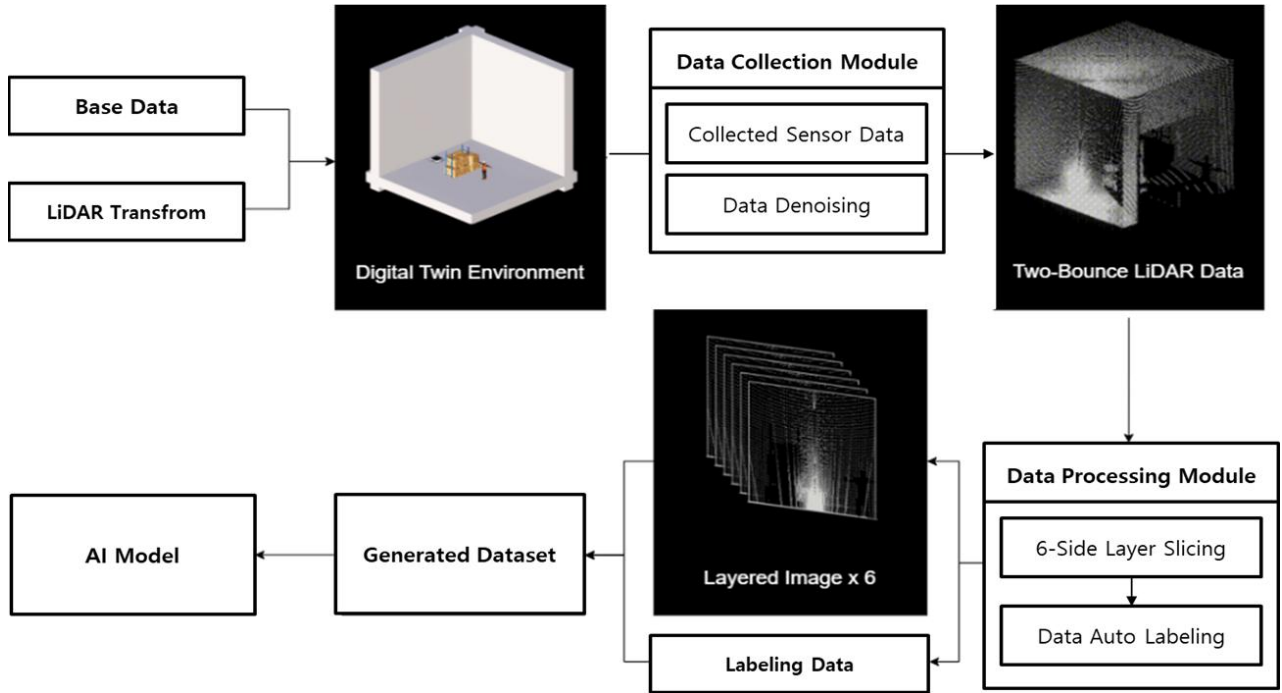


Fig. 4. Learning Flowchart of the Proposed Framework

분하여 모델링하였다. 첫 번째는 센서에서 첫 번째 반사 지점까지의 반사광, 두 번째는 첫 번째 반사 지점에서 두 번째 반사 지점까지의 반사광을 대상으로 나누어 함수를 설계하였다. 이 중 첫 번째 반사광의 방향 벡터를 계산하는 수식(1)은 아래와 같다.

$$R_1 = D - 2(D \cdot N_1)N_1 \quad (1)$$

위 수식에서 R_1 은 첫 번째 반사광의 방향 벡터이며, 입사광 벡터 D 가 표면 법선 벡터 N_1 과 이루는 각도에 따라 반사되는 방향이 결정된다. 이는 일반적인 반사 법칙을 기반으로 하며, 벡터 연산을 통해 입사 방향 대비 표면 반사각을 정밀하게 반영할 수 있도록 구성했다.

두 번째 반사광의 방향 벡터를 계산하는 수식(2)은 아래와 같다.

$$R_2 = (R_1 + \Delta\theta) - 2[(R_1 + \Delta\theta) \cdot N_2]N_2 \quad (2)$$

위 수식에서 R_2 는 두 번째 반사광의 방향 벡터이며, R_1 과 해당 위치에서의 법선 벡터 N_2 , 그리고 레이저 펄스의 확산각도 $\Delta\theta$ 를 고려하여 계산된다. 이 식은 두 번째 반사 경로를 예측하는 데 활용되며, 이 식은 두 번째 반사 경로를 예측하는 데 활용되며, 간접 반사가 이루어지는 경로의 공간적 방향성을 시뮬레이션하는 데 사용된다.

또한, 디지털 트윈 기반으로 구현된 SPAD LiDAR 시뮬레이션에서는 레이저 신호의 반사 및 감쇠 과정을 정밀하게 모사하였다. 레이저 신호는 물체 표면에서 반사되어 센서로 되돌아오는 동안 강도가 점진적으로 감소하는데, 이를 표현하기 위해 감쇠 함수를 설계하였다. 이 함수는 반사 경로와 반사 지점의 물리적 특성을 정량적으로 반영하여 다양한 반사 조건에서의 신호 강도 변화를 효과적으로 시뮬레이션할 수 있도록 한다.

레이저 경로 상에서의 신호 강도 감소를 계산하는 수식(3)은 다음과 같다.

$$I = I_0 \cdot R_{f1} \cdot R_{f2} \cdot e^{-ad} \quad (3)$$

위 수식에서 I 는 최종 레이저 펄스 강도를 나타내며 초기 강도 I_0 에서 두 반사 지점의 반사율 R_{f1}, R_{f2} 와 매질을 통과하면서 감쇠되는 정도를 나타내는 계수 a 그리고 전체 경로 길이 d 에 따라 지수적으로 감소하는 형태를 가진다.

2. Data Generation Framework

사각지대 내 객체를 효과적으로 감지하기 위해서는 간접 반사에 의해 형성되는 Object Shadow의 정보가 포함된 고품질 학습 데이터가 필수적이다. 기존의 LiDAR 시스템은 첫 번째 반사만을 활용하기 때문에, 구조물 뒤에 있는 객체에 대한 정보가 누락되는 한계가 존재한다. 이에

따라 본 연구에서는 디지털 트윈 기반 환경을 활용하여 Object Shadow를 정밀하게 시뮬레이션하고, 다양한 반사 조건을 반영한 데이터를 자동으로 생성할 수 있는 Two-Bounce LiDAR 데이터 생성 시스템을 구축하였다.

제안된 시스템은 사각지대 객체 감지 성능 향상을 위한 학습 데이터 확보를 목적으로 하며, 전체 프로세스는 크게 데이터 수집, 데이터 처리, 데이터 변환 및 라벨링의 세 가지 단계로 구성된다. Fig. 4는 제안된 프레임워크를 활용한 전체적인 흐름을 보여준다.

첫 번째 단계인 데이터 수집 모듈(Data Collection Module)은 디지털 트윈 기반의 가상 산업 환경에서 Ray 발사 방향, 장애물 위치, 반사 특성 등 다양한 시나리오 조건을 설정하고, 이를 통해 Two-Bounce 반사 정보를 포함한 Point Cloud 데이터를 수집한다. 이 과정에서는 간접 반사 경로까지 시뮬레이션 되기 때문에, 사각지대 영역에서의 객체 인식에 필수적인 Object Shadow 정보가 자연스럽게 포함된다.

두 번째 단계인 데이터 처리 모듈(Data Processing Module)에서는 수집된 Point Cloud 데이터를 기반으로 노이즈 제거를 위한 디노이징이 수행된다. 이후, 정제된 데이터는 Fig. 3과 같이 6-Side Layer Slicing 과정을 통해 전방, 후방, 좌측, 우측, 상부, 하부 여섯 개 방향으로 분할되어 2D 이미지 형태로 변환된다. 각 방향에 해당하는 Layered Image는 디지털 트윈 환경에서 설정된 시뮬레이션 환경 변수(Ray의 발사 방향, 장애물의 유무, 사람의 유무 등)에 대한 정보를 기반으로 자동 라벨링(Auto Labeling)이 진행된다. 이때 환경 변수 정보는 시뮬레이션 단계에서 자동으로 수집된다. Fig. 5는 자동 라벨링 과정을 통해 생성된 학습 데이터 샘플을 시각적으로 보여주며, 생성된 데이터에는 장애물과 사람에 의해 형성된 Object Shadow가 명확하게 표현된 것을 확인할 수 있다.

이와 같은 과정을 통해 구축된 Two-Bounce LiDAR 데이터 생성 시스템은 설정된 환경 변수에 따라 다양한 반사 시나리오 데이터를 효율적으로 생성할 수 있으며, 시뮬레이션 기반이므로 측정 환경의 변화에도 유연하게 대응할 수 있는 높은 확장성을 갖춘다. 나아가, 실제 산업 현장에서 데이터 수집이 어렵거나 비용이 많이 드는 상황에서도 본 시스템은 사각지대 객체 검출을 위한 학습 데이터를 안정적으로 제공함으로써, AI 기반 감지 모델의 일반화 성능을 실질적으로 향상시키는 데 핵심적인 역할을 수행할 수 있다.

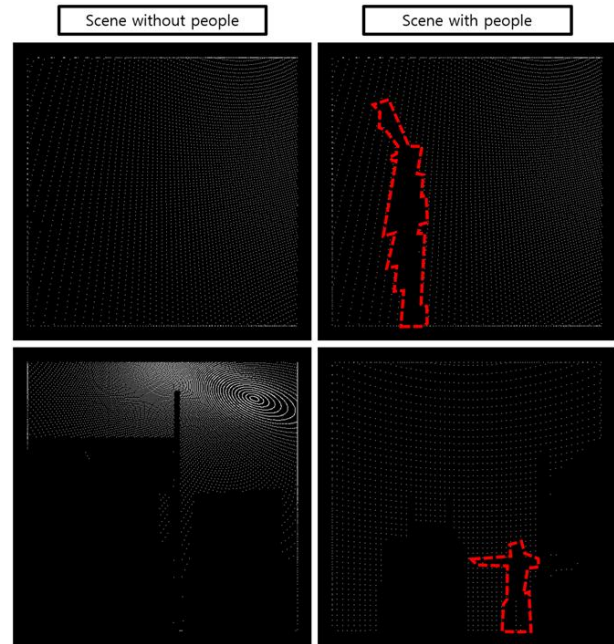


Fig. 5. Data samples generated by the proposed framework (red: object shadow from human)

IV. Experiments

1. Experimental environment

본 연구에서는 구현된 프레임워크의 성능을 검증하기 위해 디지털 트윈 환경을 활용해서 장애물과 사람의 랜덤 배치를 통해 다양한 시나리오에서 데이터를 생성하고 프레임워크의 유효성을 검증하는 데 사용하였다.

1.1 Experiment settings

실험은 Fig. 6와 같은 $10\text{m} \times 10\text{m} \times 10\text{m}$ 크기의 가상 공간에서 진행되었으며, 이 공간에는 사람, 장애물, 그리고 디지털 트윈으로 구현한 Two-Bounce LiDAR 센서가 장착된 AMR을 포함한다. AMR은 고정된 위치에서 레이저 펄스를 발사하고 Two-Bounce LiDAR 센서의 수신부 위치에서 Two-Bounce LiDAR 센서 데이터를 수집하도록 설정했다.

1.2 Place people and obstacles

각 실험 장면(Scene)에서는 $5\text{m} \times 5\text{m}$ 크기의 지정된 영역 내에 사람과 장애물을 무작위로 배치하였다. 장애물은 AMR의 직선 시야를 효과적으로 차단하도록 배치하였고, 사람 객체는 일반적인 단일 반사 센서로는 감지가 어려운 사각지대 영역에 위치시켜 복잡한 감지 상황을 재현하였다.

실험은 사람의 존재 유무와 장애물에 의한 시야 차단 여부를 조합하여 Fig. 7과 같이 총 네 가지 시나리오를 구성하였으며, 이를 기반으로 다양한 조건에서 AI 모델이 객체를 정확히 인식할 수 있는지를 평가하였다. 이러한 구성은 실제 환경에서 발생할 수 있는 다양한 감지 조건을 포괄하며, 학습 데이터의 다양성과 모델의 일반화 성능 확보에 기여하였다.




Fig. 6. Digital Twin Experimental Environment

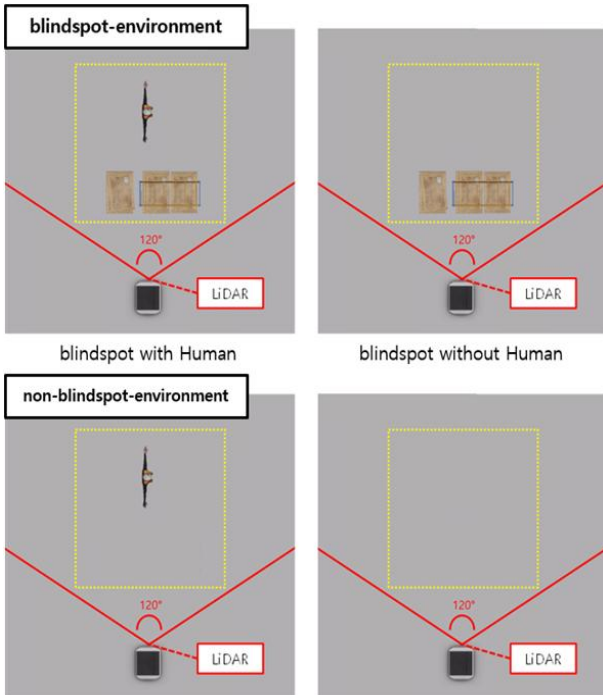


Fig. 7. Experimental simulation scenarios

1.3 Two-Bounce LiDAR Setup and Data Collection

본 연구에서는 SPAD 기반 Two-Bounce LiDAR 센서를 AMR에 탑재하고, 디지털 트윈 환경 내에서 다양한 시나리오를 시뮬레이션함으로써 실제 환경에서 수집이 어려운 복합적인 반사 상황을 데이터로 재현하였다.

LiDAR 센서는 수평 120°의 감지각을 가지며, 레이저를 발사하여 1차 및 2차 반사 신호를 수신한다. 수신된 데이터는 노이즈 제거 후 6-Side Layer Slicing 방식을 통해 여섯 방향으로 분리되며, 512 × 512 크기의 이미지 데이터를 생성한다.

이후 디지털 트윈 시뮬레이터 상의 객체 위치 및 방향 정보를 참조하여 Auto Labeling 기능을 수행하며, 각 데이터에 대해 사람 존재 여부를 자동 라벨링하였다. 이를 통해 총 12,600장의 non-blindspot-environment(일반적인 비 사각지대 환경) 데이터셋과 9,600장의 blindspot-environment(사각지대 환경) 데이터셋을 생성하였다. 이 두 데이터셋을 결합하여 Mixed-environment 데이터셋을 구성하였으며, 이후 AI 모델 학습에 활용하였다.

2. Experimental Results and Analysis

본 논문에서는 제안된 프레임워크를 활용한 데이터 증강이 AI 모델의 일반화 성능에 미치는 영향을 검증하기 위해, 실제 산업 현장에서의 실시간 운용성과 제한된 연산 자원 환경을 고려하여 경량화된 구조를 가진 딥러닝 모델들(SqueezeNet[18], EfficientNet[19], MobileNetV2[20])을 사용하였으며, 각각 해당 논문에서 제시된 베이스라인 구조를 활용하였다.

모든 모델은 동일한 학습 조건(learning rate = 0.001, batch size = 32, optimizer = Adam)으로 총 10 epoch 동안 학습하였으며, 성능 평가는 학습에 사용되지 않은 독립 테스트 데이터셋에서 200장을 샘플링하여 수행하였다.

실험에 사용된 데이터셋은 학습 및 시험 구성 각각 두 가지씩 총 네 가지 실험 구성을 설정하였다. 각 구성은 다음과 같다.

구성 1: 학습 non-blindspot-environment scenario / 시험 non-blindspot-environment case

구성 2: 학습 mixed-environment scenario / 시험 non-blindspot-environment case

구성 3: 학습 non-blindspot-environment scenario / 시험 mixed-environment case

구성 4: 학습 mixed-environment scenario / 시험 mixed-environment case

Table 2. Accuracy According to Four Experimental Configurations

Train scenario / Test case		non-blindspot-environment			mixed-environment		
		Squeeze Net	Efficient Net	Mobile NetV2	Squeeze Net	Efficient Net	Mobile NetV2
non-blindspot-environment	Accuracy	90.50	95.00	97.00	96.00	97.50	98.50
	F1 score	0.9043	0.9375	0.9700	0.9600	0.9750	0.9850
mixed-environment	Accuracy	79.50	72.00	82.00	86.00	98.50	93.00
	F1 score	0.7885	0.6980	0.8185	0.8599	0.9850	0.9308

실험에 사용된 학습 조건인 10 epoch는 초기 실험에서의 학습 곡선 및 검증 성능의 안정화 양상을 바탕으로, 모델 성능이 충분히 향상되는 시점으로 판단되었다. 실제로 Fig. 8에서 확인할 수 있듯이, Train Loss와 Validation Loss는 전반적으로 낮은 수준에서 점진적으로 수렴하는 경향을 보였으며, 이를 통해 10 epoch 내외에서 학습이 안정적으로 완료되었음을 확인할 수 있다.




Fig. 8. Training and Validation Loss over Epochs

모델 성능은 정확도(Accuracy)와 F1-score를 기준으로 비교하였으며, 이를 통해 제안한 프레임워크로부터 생성된 데이터가 실제 학습에 어떻게 기여하는지를 중심으로 일반화 성능 향상 효과를 정량적으로 검증하고자 하였다. 특히 본 실험은 시뮬레이션 기반 검증을 통해 다양한 사각지대 시나리오에서의 모델 인식 성능을 평가하였으며, 이러한 검증은 사각지대 시나리오 데이터를 포함한 학습이 모델의 일반화 성능 향상에 얼마나 도움이 되는지 정량적으로 확인하고자 하는 목적에서 수행했다.

Table 2는 상기 네 가지 실험 구성에 따라 평가된 객체 검출 정확도와 F1-score를 나타낸다. 실험 결과, non-blindspot-environment 데이터로 학습된 모델들은 구성 1에서는 높은 정확도를 보였지만, 구성 3에서는 정확도가 11%p 이상 감소하는 결과를 보였다. 이는 학습 데이

터가 특정 환경에만 국한될 경우, 환경 변화에 따른 모델 성능 저하가 크다는 점을 보여준다.

반면, 제안한 프레임워크를 통해 생성된 사각지대 데이터를 학습에 추가한 구성 2와 구성 1을 비교했을 때, 학습 데이터에 사각지대 정보를 추가함으로써 약 2%p 이상의 정확도 향상을 보였다. 이는 데이터의 다양성이 일반 환경에서도 모델의 안정성을 높이는 데 기여할 수 있음을 시사한다. 또한 구성 3과 구성 4를 비교했을 때, 사각지대 환경에서는 평균 정확도 기준 약 14.67%p, F1-score 기준으로는 약 15.69%p의 향상 폭이 기록되어, 제안된 데이터 생성 방식이 복잡한 반사 환경에 대한 일반화 성능을 실질적으로 향상시킴을 확인하였다.

Table 3은 blindspot-environment Test case에서 학습 구성의 차이에 따라 모델 성능이 어떻게 변화하는지를 정리한 것이다. 해당 테스트는 일반 시나리오가 혼합된 평가 결과로는 확인하기 어려운 사각지대 인식 성능을 독립적으로 분석하기 위해 별도로 수행되었다. 전체적으로 non-blindspot-environment 학습 모델의 평균 정확도는 38.00%였던 반면, mixed-environment 학습 모델은 평균 80.17%의 정확도를 기록하여 약 42.17%p의 향상, 즉 기존 대비 2배 이상의 성능 개선을 보였다. 이러한 결과는 사각지대 환경에서의 일반화 성능 확보를 위해서는 사각지대 데이터를 포함한 학습이 필수적임을 시사하며, 제안된 프레임워크를 통해 생성된 데이터가, 사각지대와 같은 복잡한 반사 환경에서도 모델의 일반화 성능을 향상시키는 데 실질적인 기여를 했음을 보여준다.

Table 3. Accuracy blindspot-environment Test case

Model	Train	non-blindspot-environment		mixed-environment	
		Accuracy	F1 score	Accuracy	F1 score
SqueezeNet		35.00	0.235	78.50	0.784
EfficientNet		43.50	0.404	80.50	0.800
MobileNetV2		35.50	0.267	81.50	0.813

V. Conclusion

본 논문에서는 AGV 및 AMR 운용 중 발생할 수 있는 사각지대 내 장애물 감지 문제를 해결하기 위해, Two-Bounce LiDAR 기술과 디지털 트윈 기반 데이터 생성 프레임워크를 결합한 객체 감지 시스템을 제안하였다. 제안된 프레임워크는 디지털 트윈 환경에서 사람의 존재 유무와 장애물의 유무를 고려한 총 4가지 시나리오를 시뮬레이션하여 학습 데이터를 생성하였으며, 이를 기반으로 경량 AI 모델들을 학습시켜 성능 변화를 비교하였다.

실험 결과, 사각지대 시나리오 데이터를 포함하여 학습된 모델은 기존 Normal only 구성에 비해 사각지대 객체 검출 정확도가 평균 14.67%p, F1-score 기준으로는 평균 15.69%p 향상되는 등, 전반적으로 데이터 생성으로 인한 일반화 성능 향상됨을 확인되었다. 특히 Blindspot only 테스트 시나리오에서는 정확도가 약 2배 이상 향상되었으며, 사각지대 환경에서도 평균 80.17%의 정확도를 유지하였다. 이를 통해 제안된 프레임워크가 데이터 수집의 한계를 극복하고 사각지대 객체 감지 시스템의 일반화 성능을 향상시킬 수 있음을 실험적으로 입증하였다.

향후 연구에서는 현재 시뮬레이션 기반 검증을 바탕으로, 실제 SPAD LiDAR 센서 환경에서의 테스트를 통해 실 데이터 기반 성능을 검증하고자 하며, 보다 복잡한 동적 환경, 다양한 조명 조건, 장애물 구성 변화 등 실제 현장 조건을 반영한 시뮬레이션 기반 실험을 확장하고, 필요에 따라 Transformer 기반 고성능 모델의 도입 및 멀티센서 융합 기법을 활용하여 자율주행 로봇의 인지 정밀도와 운용 안정성 향상을 목표로 연구를 고도화할 계획이다.

ACKNOWLEDGEMENT

This study was supported by the Korea Institute of Industrial Technology (KITECH-JE250012), the Korea Planning & Evaluation Institute of Industrial Technology (KEIT) (RS 2024-00507879), and the Ministry of SMEs and Startups (MSS RS-2023-00225527).

REFERENCES

- [1] Y. Bekishev, Z. Pisarenko, and V. Arkadiev, "FMEA model in risk analysis for the implementation of AGV/AMR robotic technologies into the internal supply system of enterprises," *Risks*, vol. 11, no. 6, pp. 1-31, 2023.
- [2] M. Boehning, "Improving safety and efficiency of AGVs at warehouse black spots," in *Proc. IEEE 10th Int. Conf. Intell. Comput. Commun. Process. (ICCP)*, 2014, pp. 245-249.
- [3] M. Wenning, A. A. Backhaus, and T. Adlon, "Testing the reliability of monocular obstacle detection methods in a simulated 3D factory environment," *J. Intell. Manuf.*, vol. 33, no. 7, pp. 2157-2165, 2022.
- [4] H.-C. Yoon and T.-H. Park, "Auto-parking controller of omnidirectional mobile robot using image localization sensor and ultrasonic sensors," *J. Inst. Control, Robot. Syst.*, vol. 21, no. 6, pp. 571-576, Dec. 2015. (in Korean)
- [5] Z. Qiu, Y. Lu, and Z. Qiu, "Review of ultrasonic ranging methods and their current challenges," *Micromachines*, vol. 13, no. 520, pp. 1-33, 2022.
- [6] T. Klinghoffer, X. Xiang, S. Somasundaram, Y. Fan, C. Richardt, R. Raskar, and R. Ranjan, "PlatoNeRF: 3D reconstruction in Plato's cave via single-view two-bounce LiDAR," in *Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2024, pp. 14565-14574.
- [7] D. Lee, M. Jung, and W. Yang, "LiDAR odometry survey: recent advancements and remaining challenges," *Intell. Serv. Robot.*, vol. 17, no. 2, pp. 95-118, 2024.
- [8] R. Geng, Y. Hu, and Y. Chen, "Recent advances on non-line-of-sight imaging: Conventional physical models, deep learning, and new scenes," *APSIPA Trans. Signal Inf. Process.*, vol. 11, no. 1, pp. 1-48, 2022.
- [9] B. Wang, S. Li, Z. Wang, and Y. He, "Human digital twin in the context of Industry 5.0," *Rob. Comput.-Integr. Manuf.*, vol. 85, article 102626, 2024.
- [10] S.-H. Shin and M.-C. Park, "Design of an exploration drone for digital twin-based building control," *J. Korea Soc. Comput. Inf.*, vol. 26, no. 5, pp. 9-16, May 2021.
- [11] S. Mihai, G. Prelicean, A. Candel, and F. Sandu, "Digital twins: A survey on enabling technologies, challenges, trends and future prospects," *IEEE Commun. Surveys Tuts.*, vol. 24, no. 4, pp. 2255-2291, 2022.
- [12] A. Dosovitskiy, G. Ros, F. Codevilla, A. Lopez, and V. Koltun, "CARLA: An open urban driving simulator," in *Proc. Conf. Robot Learn. (CoRL)*, PMLR, 2017, pp. 1-16.
- [13] S. Shah, D. Dey, C. Lovett, and A. Kapoor, "Airsim: High-fidelity visual and physical simulation for autonomous vehicles," in *Field and Service Robotics*, Springer, 2018, pp. 621-635.
- [14] D. A. Guerra-Zubiaga, A. K. M. M. Islam, and A. P. Cusworth, "Digital twin in a manufacturing integrated system: Siemens TIA and PLM case study," in *Proc. ASME Int. Mech. Eng. Congr. Expo.*, vol. 59384, 2019.
- [15] N. V. Zorchenko, T. G. Tyupina, and M. E. Parshutin,

“Technologies used by General Electric to create digital twins for energy industry,” *Power Technol. Eng.*, vol. 58, no. 3, pp. 521–526, 2024.

- [16] C. Henley, J. Hollmann, and R. Raskar, “Bounce-flash LiDAR,” *IEEE Trans. Comput. Imaging*, vol. 8, pp. 411–424, 2022.
- [17] S. Scholes and J. Leach, “Path tracing-inspired modeling of non-line-of-sight SPAD data,” *Sensors*, vol. 24, no. 20, article 6522, Oct. 2024.
- [18] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. Chen, “MobileNetV2: Inverted residuals and linear bottlenecks,” in *Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2018, pp. 4510–4520.
- [19] F. Iandola, S. Han, M. Moskewicz, K. Ashraf, W. Dally, and K. Keutzer, “SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size,” *arXiv preprint, arXiv:1602.07360*, 2016.
- [20] M. Tan and Q. Le, “EfficientNet: Rethinking model scaling for convolutional neural networks,” in *Proc. Int. Conf. Mach. Learn. (ICML)*, 2019, pp. 6105–6114.

Authors



Jae-Hun Hwang received the B.S. degree in Smart Convergence Engineering from Hanyang University, ERICA, in 2023. He is currently pursuing the M.S. degree in Artificial Intelligence Convergence at

Hanyang University since 2024. His research interests include digital twins, AR/VR, robotics applications, and process systems.



Seung Yeop Ha received the B.S. degree in Display Engineering from Dankook University in 2022. He is currently pursuing an integrated M.S.-Ph.D. degree in Industrial Management Engineering at Korea University

since 2024. His research interests include explainable AI and digital twins.



Jun-Seok Yun received the M.S. degree in Artificial Intelligence Convergence from Chonnam National University in 2023. Since 2023, he has been a researcher at the Manufacturing AI Research Center, Korea

Institute of Industrial Technology. His research interests include image super-resolution, semantic segmentation, defect detection, and anomaly detection.



Min Su Kim received the B.S., M.S., and Ph.D. degrees in Electronic Engineering from POSTECH, in 2014, 2016, and 2022, respectively. Since 2024, he has been a senior researcher at the Korea Institute of

Industrial Technology. His research interests include data-driven defect analysis, signal processing, and deep neural networks.



Sanga Lee received the B.S., M.S., and Ph.D. degrees in Mechanical and Aerospace Engineering from Seoul National University, in 2010, 2012, and 2017, respectively. Since 2019, she has been a principal researcher at

the Korea Institute of Industrial Technology. Her research interests include artificial intelligence and simulation integration.



Jong Pil Yun received the B.S. degree in Electrical and Electronic Engineering from Kyungpook National University in 2003, and the Ph.D. degree in Electronic Engineering from POSTECH in 2009. From 2009 to

2016, he was a senior researcher at POSCO. Since 2016, he has been a principal researcher at the Korea Institute of Industrial Technology. His research interests include artificial intelligence, machine vision, defect inspection, equipment diagnostics, and medical data analysis.



Hong-In Won received the Ph.D. degree in Mechanical Design Engineering from Hanyang University in 2017. Since 2017, he has been a principal researcher at the Korea Institute of Industrial Technology.

His research interests include artificial intelligence, data mining, digital twins, and automatic control of manufacturing systems.