

비가시 공간 및 MIMO 안테나 구성에 따른 레이더 신호를 이용한 딥러닝 기반 물체 분류에 관한 연구

이 상 원*, 최 계 원^o

A Study on Object Classification Based on Deep Learning Using Radar Signal According to Invisible Area and MIMO Antenna Configuration

Sang-Won Lee*, Kae-Won Choi^o

요 약

비가시 공간의 물체를 탐지하는 기술은 일반적인 시야에서 볼 수 없는 영역 내 물체를 인식하는 기술이며, 군사 작전 및 인명구조, 자율 주행 등의 분야에 주목받고 있다. RF 레이더 신호는 벽을 투과하는 특성을 보유하고 있어 비가시 공간이라는 특수한 환경에서 물체를 탐지하기에 적합하다고 볼 수 있다. 이때 RF 신호가 비가시 환경을 구성하는 장애물을 투과할 때 손실이 발생하는데, 해당 손실로 인해 비가시 물체 탐지 기술에 대한 성능이 낮아지게 된다. 이를 해결하기 위해 본 논문에서는 다중 송·수신 안테나 기술을 적용하였고, 초광대역 레이더 칩을 통해 RF 레이더 신호 수집 실험 환경을 구성한다. 또한, 비가시 공간을 구성하는 벽체 및 다중 송·수신 안테나 구성을 변경하면서 RF 신호 데이터셋을 수집하고, 해당 데이터셋을 입력값으로 두어 기계학습 및 딥러닝 모델을 통해 출력된 물체 분류 결과를 비교 및 분석한다. 이를 통해 다양한 벽체와 안테나 배열 구성을 통해 신호 손실 또한 달라짐에 따라 물체 탐지 성능에 영향이 미치는지를 확인한다.

Key Words : Radar, MIMO, Object Classification, Invisible Area, Deep Learning

ABSTRACT

The technology for detecting objects in invisible area is a technology for recognizing objects in an area that cannot be seen in general view, and is attracting attention in fields such as military operations, lifesaving, and autonomous driving. The RF radar signal has the characteristic of penetrating wall, so it is considered suitable for detecting an object in a special environment called invisible area. At this time, a loss occurs when the RF signal passes through an obstacle constituting an invisible environment, and the loss results in a lower performance of the invisible object detection technology. In this paper, multiple transmit/receive antenna technology is applied to solve this problem and an RF radar signal collection experiment environment is constructed through an ultra-wideband radar chip. The RF signal dataset is collected while changing the type

* 이 논문은 2022년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원(No. 2020-0-00973, VR·AR 콘텐츠 비가시 영역 영상 복원 기술 개발)을 받아 수행된 연구임.

• First Author : Sungkyunkwan University Department of Electrical and Computer Engineering, kl0081kl@g.skku.edu, 학생회원

^o Corresponding Author : Sungkyunkwan University Department of Electrical and Computer Engineering, kaewonchoi@skku.edu, 종신회원

논문번호 : 202205-070-D-RE, Received April 27, 2022; Revised July 8, 2022; Accepted July 11, 2022

of the wall and antenna arrangement, and the object classification results output through machine learning and deep learning models were compared and analyzed. Through this, it is verified through whether the object detection performance is affected as the signal loss also varies through various wall and antenna arrangement configurations.

1. 서 론

비가시 공간에서 특정 물체를 탐지하는 기술은 자율 주행 시스템 및 소방·안전, 군사 작전 등에 활용될 수 있는 차세대 기술로 주목받고 있다. 먼저 자율 주행 분야에서는 높은 수준의 자율 주행을 구현하기 위해 시야가 확보되지 않은 공간에서 비가시 영역 탐지 기술을 활용하여 사고가 날 만한 상황을 예측하여 안전성을 보장할 수 있다는 이점을 지니고 있다. 다음으로 안전에 직접적으로 관련되어있는 인명구조 작전에서도 비가시 영역 탐지 기술이 활용될 수 있는데, 화재 상황이나 진물이 무너져 있는 재난 상황에서 비가시 영역 탐지 기술을 통해 구조 인원들이 직접적으로 탐지하기 힘든 구조 대상자를 찾아 구조 활동을 수월하게 만들 수 있다. 마지막으로 군사 작전에서 은·엄폐 중인 적군을 탐지하여 군사 작전을 성공적으로 수행하고 아군의 인명피해를 최소화할 수 있다^[1].

이러한 비가시 영역에서의 물체 탐지 기술을 구현하기 위해 레이더 센서를 이용하는데, 레이더 센서의 RF(Radio Frequency) 신호를 사용하여 시야에 잘 보이지 않거나 가려져 있는 물체의 탐지 및 추적^[2,5]이나 사람의 행동 추정 및 인식^[6,7], 더 나아가 삼차원으로 사람의 형태를 복원^[8]하는 연구가 이루어지고 있다.

위의 논문들은 공통적으로 레이더 센서의 RF 신호의 특성을 사용하였는데, 해당 특성은 RF 신호가 주파수에 따라 투과도가 달라짐에 따라 주파수를 조정하여 벽체를 투과할 수 있는 특성이다. 위와 같은 RF 신호의 특성을 통해 비가시 공간에서의 물체 탐지 기술을 구현하기 위해, 해당 논문에서는 레이더의 기술 중 하나인 IR-UWB(Impulse Radio-Ultra Wide Band) 레이더를 사용한다. IR-UWB 레이더는 IR(Impulse Radio)를 사용하여 저출력 및 순간적으로 짧은 임펄스 신호를 방사하고, 전파의 투과성도 우수하여 비가시 영역 탐지 기술을 구현하기에 적합하다^[9].

레이더 센서에서 생성된 RF 신호는 전자기파임에 따라 전자기파의 매개체 간 투과율은 각각의 유전율에 기인하여 각각 다른 소재에 따른 RF 신호의 투과율 및 반사율이 다양하게 나타난다. 이때 RF 신호가 벽체와 같은 장애물을 투과할 때 신호의 세기가 감쇠

하는데, 이로 인해 측정 물체에서 반사된 신호가 담고 있는 정보에 손실이 발생하여 해당 물체에 대한 정보를 사용하여 측정 물체를 특정하기에 충분치 않다는 어려움이 존재한다. 또한, 각각 다른 소재의 벽체를 투과하여 측정 물체에 반사된 RF 신호는 각각 측정 물체에 대한 정보 손실의 정도가 서로 다르게 수집된다. 이때, 비가시 공간을 구성하는 벽체의 소재라는 변수를 고려하여 비가시 라는 특수한 환경에서 물체를 탐지하는 기술을 구현하면, 비가시 공간에 동일한 물체라도 다른 소재의 벽체를 통해 정확도가 달라지는 문제점을 해결하여 성능에 대한 일반화를 기대할 수 있다.

본 논문에서는 IR-UWB 레이더 시스템을 구성하여, RF 신호를 송·수신하고 해당 물체에 대한 데이터를 수집한다. 이때, 우선 벽체를 포함한 외부 환경에 의한 신호 세기 감쇠로 발생하는 정보의 손실을 줄이기 위해, 다수의 송신 안테나와 수신 안테나를 일정한 간격으로 배치하여 안테나 배열을 구성하는 MIMO(Multi-Input Multi-Output, 다중 안테나 기술)^[10]을 해당 레이더 시스템에 적용한다. MIMO 안테나 배치를 구성한 다음, 서로 다른 소재의 벽체를 통해 비가시 공간을 구성하고 해당 공간에 측정 물체를 두어 실험 환경을 설정한다. 이때 각각의 소재로 이루어진 벽체로 실험 환경을 구성하였을 때, 수집한 RF 신호가 측정 물체에 대한 정보량에 차이가 존재하는지를 보이기 위해 딥러닝의 물체 분류 모델로 결과를 도출하여 확인하며, 이때 물체 분류 모델은 합성곱 신경망(CNN, Convolutional Neural Network) 기반 딥러닝 네트워크 모델^[11]로 구성하였다.

또한, MIMO 안테나 배열 구성에 변화를 주었을 때 RF 신호의 측정 물체에 대한 정보량이 상이한지를 분석하기 위해, 세 가지 구성의 안테나 배열을 통해 RF 신호를 수집하였다. 해당 안테나 배열은 송·수신 안테나 6개씩의 구성(6 by 6)과 3개씩의 구성(3 by 3), 그리고 1개씩의 구성(1 by 1)으로 변경하면서 데이터를 수집하였고, 각각의 배열에 대한 가상 안테나 배열을 구성하여 측정 물체에 대한 해상도를 구하였다. 이를 통해 안테나 배열 구성의 변화로 인한 해상도가 달라짐에 따라, 각각의 안테나 배열 구성으로

인해 RF 신호에서의 측정 물체에 대한 정보 손실의 정도가 상이함을 물체 분류 모델을 통해 도출된 결과로 분석한다.

마지막으로, 동일한 벽체와 안테나 구성으로 수집된 RF 신호에 서로 다른 물체 분류 모델로 학습을 하여, 분류 모델에 따라 물체 분류 정확도에 영향이 미치는지도 비교 및 분석한다.

II. 데이터 수집 과정

RF 신호를 수집하는 과정은 다음과 같은데, 우선 레이더 센서에서 RF 신호를 생성하고, 이를 송신부 안테나에서 송출하여 비가시 영역을 구성하는 벽을 투과하게 된다. 그 후 RF 신호는 벽 뒤에 있는 목표 물체에 반사되며 수신부 안테나를 통해 수신되고, 이 신호를 데이터 형태로 저장한다. 해당 장에서는 IR-UWB 레이더 시스템 설계 및 MIMO 안테나 배열 구성 설계를 통해 RF 신호를 송·수신하는 과정을 소개하고, 데이터 수집 환경 구성을 설명하여 측정 물체 및 공간에 대한 세부적인 내용을 설명한다.

2.1 IR-UWB 레이더 시스템 설계

비가시 영역에서 물체를 탐지하기 위해 해당 시스템은 [그림 1]과 같이 PC와 연동되어 있는 IR-UWB 레이더 모듈을 통해 RF 신호를 생성한다. 생성된 신호를 증폭기로 신호 세기를 높인 다음, 다수의 송·수신 안테나로 비가시 공간에서 벽체를 투과하고 물체에 반사되는 RF 신호를 수집한다. [그림 1]을 참고하면, RF 신호를 생성하는 IR-UWB 레이더 송·수신기는 Novelda 사의 NVA 6100가 탑재된 동일 사의 NVA-R631를 사용하였고, 주파수 대역폭이 0.45 ~ 3.55GHz, 약 7.8mm의 거리 분해능을 구현해준다.

다음 과정으로는 IR-UWB 레이더 모듈을 통해 RF 신호를 생성하여 증폭기에 보내고, 이를 송신 안테나 스위치에 분배가 되어 다수의 송신 안테나로 전달된다. 이때 송신 안테나에서 송출된 RF 신호가 벽체에

투과되고 물체에 반사될 때 신호의 세기가 감소하는데, 수신 안테나가 작은 세기의 RF 신호를 수신하게 되면 해당 데이터에 대한 물체 분류 학습이 되지 않게 된다. 이를 해결하기 위해 증폭기를 레이더 모듈에 연결하여 송신할 RF 신호를 증폭시켜, 수신 안테나에 저장되는 RF 신호의 세기가 비교적 크게끔 구성한다. 증폭기는 SHF Communication Technologies AG 사의 SHF S126 A 증폭기를 사용하여 해당 대역폭의 주파수 신호들의 세기를 30dBm 만큼 증폭시켰으며, 증폭기의 적정 전압 및 전류를 전원공급장치로 공급하여 증폭기를 가동하였다.

증폭시킨 RF 신호를 다수의 송신 안테나로 전달하고 다수의 수신 안테나에서 받은 RF 신호를 송·수신기에 전달하기 위해 안테나 스위치를 사용하게 된다. 송신 안테나 스위치는 증폭기를 통해 증폭된 RF 신호를 다수의 송신 안테나로 전달해주는 역할을 지니는데, 매우 짧은 시간 간격으로 하나의 송신 안테나에 해당 신호를 전달해주게 되어, 거의 동시적으로 다수의 송신 안테나가 신호를 송신하게 된다. 수신 안테나 스위치 또한 마찬가지로 다수의 수신 안테나가 각각 RF 신호를 수신하게 되는데, 수신 안테나 스위치를 통해 IR-UWB 레이더 송·수신기에 동시다발적으로 전달하여 데이터를 수집한다. 송·수신 안테나 스위치는 pSemi 사의 PE41412, PE41512를 사용하여 약 40us의 스위칭 시간으로 다수의 레이더 안테나에 RF 신호를 거의 동시에 송·수신하게끔 해준다.

마지막으로 RF 신호를 송·수신하는 안테나는 Novelda 사의 비발디 안테나인 NVA-A03를 사용하였고, 1.3 ~ 4.4GHz의 주파수 대역을 지원하여 RF 레이더 칩에서 생성되는 RF 신호와 호환이 되게끔 구성하였다.

2.2 MIMO 안테나 배열 구성

MIMO 안테나 배열은 다수의 송신 안테나와 수신 안테나를 배열로 구성하여 측정 물체에 반사된 신호를 얻게 되는데, 이때 제한된 안테나의 개수에서 송신 안테나와 수신 안테나를 분배하여 해당 측정 물체에 대한 높은 해상도를 지닌 신호를 효율적으로 수집할 수 있다.

또한, 안테나 간의 간격을 계산하여 측정 물체에 대한 RF 신호가 유효한 공간을 분석할 수 있다는 이점을 지니고 있다. MIMO 안테나 배열을 구성하는 데에 있어서 안테나 간의 간격은 중요한 요소 중 하나인데, 이는 가상 안테나 배열을 통해 간격을 조절할 때마다 직관적으로 분석할 수 있다. [그림 2]를 참고하면, 가




그림 1. IR-UWB 레이더 시스템
Fig. 1. IR-UWB radar system




그림 2. 가상 안테나 설정 과정
Fig. 2. Virtual antenna setup process

상 안테나 배열은 MIMO 안테나 배열에서 각각 송·수신 안테나 간의 쌍을 짓고 해당 송·수신 안테나에 대하여 송신 안테나와 수신 안테나의 중간 위치 지점을 두어, 해당 지점에 송·수신을 모두 수행하는 일종의 송수신기를 가정하여 배열을 구성한 모습을 띤다.

가상 안테나 배열을 자세히 설명하기 위해 [그림 3]을 참고하면, 우선 해당 송신 안테나와 수신 안테나가 아주 멀리 있는 대상에 신호를 송·수신한다고 가정한다. 이를 통해 각 송·수신 안테나에서 대상과의 각도가 θ 로 같음을 유추할 수 있으며, 송신 안테나에서 해당 물체까지 신호가 간 거리를 d_{tx} 로 두면 수신 안테나에서 해당 물체까지의 거리 d_{rx} 는 $d_{tx} + d \sin \theta$ 임을 도출할 수 있다.

이때 송수신기를 송신 안테나와 수신 안테나 간의 거리 중간 지점에 두고 해당 지점에서부터 물체까지의 거리 $d_{virtual}$ 는 $2(\frac{d}{2} \sin \theta + d_{tx})$ 의 값을 보이며, 이는 송신 안테나에서 출력된 신호가 물체에 반사되고 수신 안테나에 도착하는 거리와 같음을 볼 수 있다.

위와 같이 송·수신 안테나 배열을 가상 안테나 배열로 재구성하여 측정 물체에 대한 2차원 해상도를 구할 수 있으며, 이를 통해 안테나 개수와 데이터 수집 환경을 비용과 공간적인 측면에서 효율적으로 설

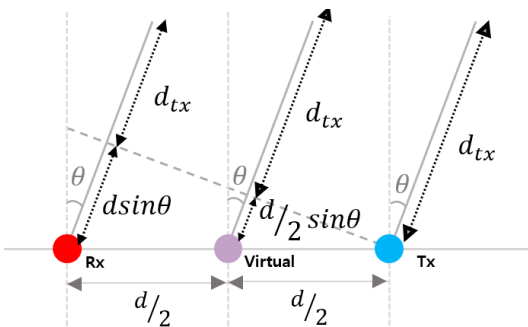


그림 3. 가상 안테나 송수신기 구성
Fig. 3. Virtual antenna transceiver

정할 수 있다.

본 논문에서는 IR-UWB 레이더 시스템을 통해 비가시 영역에서 탐지하고자 하는 물체에 대한 정보를 RF 신호 데이터로 수집하였으며, 이때 물체 분류 모델에 학습시키기 위한 측정 물체에 대한 충분한 정보를 얻기 위해 [그림 4]와 같이 각각 6개씩의 송·수신 안테나를 배치하여 MIMO 안테나 배열을 구성하였다. 해당 그림처럼 송신 안테나 6개와 수신 안테나 6개를 각각 높이 20cm, 너비 15cm만큼 이격시켜 배치하였다.

[그림 2]는 [그림 4]에서의 MIMO 안테나 배열을 통해 가상 안테나 배열을 구성하는 과정을 그린 모습이다. 해당 송신 안테나와 수신 안테나의 중간 위치 지점에 가상의 송수신기 안테나를 배치하며, 이를 각각 모든 송·수신 안테나 간의 쌍을 지어 가상 안테나를 그리면 [그림 5]와 같이 구성됨을 볼 수 있다. 각 6개의 송·수신 안테나를 통해 36쌍의 가상 안테나 배열이 구성되는데, 이때 가상 안테나의 위치가 중복되는 지점에서는 해상도가 겹쳐지는 모습을 확인할 수 있다.




그림 4. 레이더 안테나 배치도
Fig. 4. Radar antenna layout




그림 5. 가상 안테나 배열
Fig. 5. Virtual antenna array

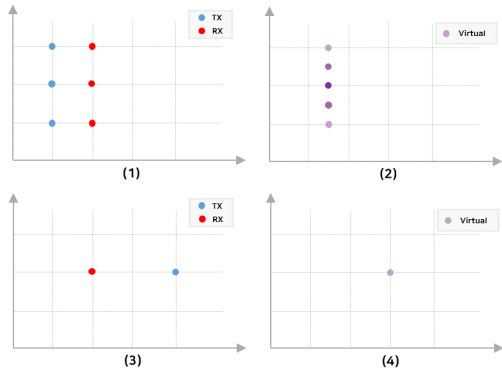


그림 6. (1) 3 by 3 안테나 배치, (2) (1)의 가상 안테나 배열, (3) 1 by 1 안테나 배치, (4) (3)의 가상 안테나 배열
 Fig. 6. (1) 3 by 3 antenna layout, (2) Virtual Array of (1), (3) 1 by 1 antenna layout, (4) Virtual Array of (3)

본 논문에서는 MIMO 안테나 배열 구성에 변화를 주었을 때 RF 신호의 측정 물체에 대한 정보량이 다른지를 분석하기 위해 [그림 6]과 같이 안테나를 배치하였다. 송신 안테나와 수신 안테나를 3개씩 구성한 배열, 즉 3 by 3 안테나 배열은 [그림 6]의 (1)와 같이 구성하였으며, 이에 대한 가상 안테나 배열은 (2)와 같이 구성된다. 또한, 1 by 1 안테나 배열은 (3)과 같이 배치하였고, 이에 대한 가상 안테나 배열은 (4)와 같은 그림으로 구성됨을 볼 수 있다.

2.3 데이터 수집 환경 구성

본 논문에서는 각각 다른 소재로 구성된 벽체를 설치하여 비가시 공간을 설정하고, 이 공간에 물체를 위치하여 IR-UWB 레이더 시스템을 통해 데이터를 수집하였다.

이때 벽체는 PVC, 알루미늄, 스티로폼으로 선정하여, 각 벽체가 서로 다른 소재로 구성됨에 따라 RF 신호의 투과율 및 반사율 또한 서로 상이하게끔 구성하였다. 측정 물체는 의자, 사람, 마네킹으로, 의자의 규격은 45×47×130cm, 마네킹은 20×30×140cm, 사람은 30×40×175cm의 크기이다[그림 7]. 벽체의 크기는 가로 1.3m, 세로 1m로 제작하여 레이더 안테나 배열과 물체의 크기를 충분히 가릴 수 있게끔 구성, 두께는 5mm의 크기로 구성하였다.

[그림 8]은 본 논문에서 벽체별로 물체 분류 학습을 위해 RF 신호 데이터를 수집할 목적으로 구성한 공간을 나타낸다. 벽체는 MIMO 레이더 안테나의 위치로부터 50cm 이격하였고, 비가시 공간인 해당 측정 공간은 벽체와 20cm 떨어지게끔 구성하였으며 넓이는 각 가로, 세로 1m로 설정하였다. 또한, 설정된 측정

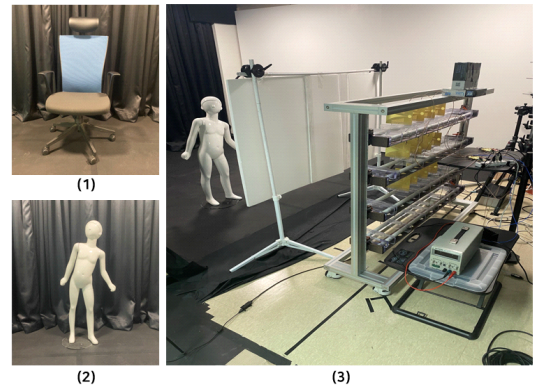


그림 7. (1) 의자, (2) 마네킹, (3) 테스트베드
 Fig. 7. (1) chair, (2) Mannequin, (3) Testbed




그림 8. 데이터 수집 모델
 Fig. 8. Data collection model

공간에서 측정 물체의 위치와 각도를 변경하면서 데이터를 수집하였다.

III. 물체 분류 모델 구성

IR-UWB 레이더 시스템과 MIMO 안테나 배치, 그리고 벽체를 구성하여 RF 신호 데이터셋을 구성한 다음으로, 해당 데이터셋을 통해 딥러닝을 통한 물체 분류를 진행하기 위해 먼저 데이터셋에 대한 전처리 과정을 진행한 다음, 물체 분류 모델을 구성하고, 이에 대한 손실 함수 및 최적화 함수에 대해 언급한다.

3.1 RF 신호 데이터셋

우선 물체 분류 모델을 구성하기 전에, 수집한 RF 신호 데이터셋에 대한 구조부터 살펴보면 다음과 같다. IR-UWB 레이더 칩을 통해 RF 신호를 송출하고, 각각 하나의 송·수신 안테나로 수집된 RF 신호 데이터는 총 1,024개의 샘플로 구성되어 있으며 [그림 9]을 통해 RF 신호를 확인할 수 있다. 해당 그림의 x축은 해당 안테나와의 거리를 나타내며, y축은 신호의 진폭을 나타낸다. 이를 통해 각각 6개씩의 송·수신




그림 9. 각 벽체, 물체별 RF 신호
Fig. 9. RF signal for each wall and object

안테나로 수집된 RF 신호 데이터는 36개의 안테나 쌍과 각각의 1,024 샘플에 의해 (6×6×1024)의 구조로 구성되어 있음을 볼 수 있다. 이를 (36×1024)의 구조로 재구성하여 전처리 과정을 수행한다.

[그림 9]을 보면, 벽체와 탐지된 물체를 통해 수집된 RF 신호의 형태와 해당 신호가 어떤 벽체를 통과하여 수집되었는지는 판별할 수 있지만, 해당 벽체에 어떤 물체인지를 분류하는 작업은 직관적으로는 쉽지 않아 보인다. 이 한계점을 해결하기 위해 본 논문에서는 해당 데이터를 딥러닝의 물체 분류 모델에 적용하여 물체 분류에 대한 정확도를 출력한다.

이때 RF 신호 데이터셋을 크게 세 분류로 나눌 수 있는데, 각각 6개, 3개, 1개씩의 송·수신 안테나 쌍으로 구성된 배열로 분류할 수 있다. 각각 분류된 데이터셋마다 각 벽체의 소재에 따라, 그리고 각 벽체 소재마다 세 가지 종류의 측정 물체에 따라 데이터셋이 분류된다. 이렇게 분류된 데이터셋을 통해 딥러닝의 물체 분류 모델에 적용하여 송·수신 안테나 배열의 변화로 발생한 RF 신호 해상도 차이로 인해 물체 분류 정확도가 다른지에 대해 확인한다.

3.2 물체 분류 모델

본 논문에서는 RF 신호의 해상도 차이로 인한 분류 정확도 차이뿐만 아니라 물체 분류 모델에 의한 분류 정확도 또한 비교·분석하기 위해 세 가지의 물체 분류 모델을 구성하였다. 처음 두 모델은 합성곱 신경망으로 구성되어 있으며, 이 중 하나는 2015년도에 나온 ResNet 모델의 일종인 ResNet-18을 사용하였다^[12]. 나머지 모델은 딥러닝을 통해 출력된 물체 분류 정확도와 비교하기 위해, 기계학습의 SVM(Support Vector Machine) 모델을 사용하였다.

[그림 10]을 참고하여 설명하면, 우선 RF 신호 데이터의 구조에 맞춰 합성곱 신경망의 입력값으로 설정하고, 합성곱 신경망에서 알맞은 커널(Kernel)의 크




그림 10. 물체 분류 딥러닝 모델
Fig. 10. Object classification deep learning model

기를 설정하여 해당 RF 신호의 특징을 추출하는 작업을 진행한다. 여러 합성곱의 은닉층(Hidden Layer)을 거치게 되어 마지막 계층인 완전 연결 계층(Fully Connected Layer)에 도달하게 된다. 이때의 출력값을 분류기(Classifier)의 한 종류인 Softmax 함수에 적용하는데, 이 분류기는 아래의 수식을 통해 K 인 물체 종류의 수를 적용하면, 각각의 물체 종류인지에 대한 확률 편차를 확대시키고 해당 출력값을 정규화하여 출력값들의 총합을 1로 만든다.

$$p_j = \frac{e^{x_j}}{\sum_{k=1}^K e^{x_k}} \text{ for } j = 1, 2, \dots, K \quad (1)$$

이때 출력값의 개수가 물체 종류의 개수와 일치하며, 각각의 출력값은 한 종류의 물체를 대변한다. 만약 임의의 출력값이 다른 출력값보다 크면, 이 출력값은 입력값인 RF 신호가 해당 출력값이 대변하는 물체의 종류임을 높은 확률로 특정할 수 있다.

학습을 위한 손실 함수는 Cross Entropy Loss를 사용하였고, 최적화 함수는 Adam를 사용, 학습 속도는 2×10^{-3} 으로 설정하였다.

IV. 학습 결과

세 종류의 벽체별로 비가시 영역을 구성하여 탐지하고자 하는 물체에 대해서 RF 신호 수집을 완료하고, 세 가지의 물체 분류 모델을 구성하여 이를 통해 합성곱 계층의 구성 차이로 인해 물체 분류 정확도가 상이한지를 확인할 수 있다. 그다음으로 MIMO 구성에 차이를 두어 수집된 RF 신호를 입력값으로 설정하고, 동일한 물체 분류 모델로 학습하여 물체 분류 정확도에 영향을 끼치는지 분석하였다.

4.1 물체 분류 모델별 학습 결과

우선 각각 6개씩의 송·수신 안테나를 통해 구성된 MIMO 안테나 배치를 기준으로, 세 가지의 벽체를 통

해 수집된 RF 신호 데이터를 세 물체 분류 모델의 입력값으로 두어 학습을 진행한 결과는 [표 1]과 같다. 첫 번째 모델은 기계학습의 SVM 모델을 사용하였고, 두 번째 모델은 3개의 합성곱 계층과 하나의 완전 연결 계층으로 구성된 CNN-4을 통해 결과값을 출력한다. 이때의 두 모델에 출력된 정확도는 높은 순으로 스티로폼, PVC, 알루미늄 순이며, [그림 11, 12]를 참고하면 물체별로 각각 1,000개의 테스트 데이터셋을 통해 오차 행렬을 구하였으며, 스티로폼을 벽체로 구성하였을 때 세 종류의 물체를 정확하게 분류했음을 확인할 수 있지만, 벽체가 알루미늄과 PVC일 때는 물

체 분류 정확도가 상대적으로 낮음을 알 수 있다.

이에 반해, 세 번째 물체 분류 모델인 ResNet-18은 합성곱 계층과 완전 연결 계층을 포함하여 총 18개의 계층으로 구성되어 있으며, 이때 [그림 13]을 보면 세 가지 벽체로 비가시 공간을 구성했을 때 모두 물체 분류를 큰 차이 없이 정확하게 수행했음을 확인할 수 있다.

4.2 안테나 배치 구성별 학습 결과

본 논문에서는 RF 신호를 수집할 때 물체에 대한 보다 높은 해상도로 수집하기 위해 다수의 송·수신 안테나를 배치하였으며, 해상도 차이로 인해 물체 분류 정확도가 상이한지를 확인하였다.

먼저 두 물체 분류 모델 중 우수한 학습 결과를 보여준 ResNet-18을 사용하였고, 안테나 배치를 각각 6개씩, 3개씩, 1개씩의 송·수신 안테나를 [그림 4], [그림 6]과 같이 구성하였다. 이때 각각의 안테나 배치별 학습 결과는 [표 2]와 같다.

ResNet-18 모델을 기준으로 각각의 안테나 배치 구성에 따른 물체 분류 학습을 진행한 결과, [그림 13, 14, 15]와 같이 벽체가 알루미늄과 PVC일 때 각각의 안테나 배치 구성에 따른 정확도 차이가 미미하게 존재함을 볼 수 있고, 스티로폼일 때는 안테나 배치 구성으로 인한 정확도 차이가 존재하지 않음을 볼 수 있다.

안테나 배치 구성에 따른 정확도 차이를 큰 편차로 확인하기 위해 또 다른 분류 모델인 CNN-4를 사용하여 정확도를 도출하였다. [표 3]을 참고하면, 벽체가 알루미늄일 때와 PVC일 때 각 안테나 배치 구성별 정확도 차이를 구분할 수 있는 반면에, 벽체가 스티로

표 1. 물체 분류 모델별 정확도
Table 1. Accuracy by object classification model

MIMO : 6 by 6	Aluminium	Styrofoam	PVC
SVM	88.33%	98.33%	83.67%
CNN-4	88.23%	99.74%	82.41%
ResNet-18	99.60%	99.97%	99.87%




그림 11. SVM을 통한 각 벽체에 대한 오차 행렬
Fig. 11. Confusion matrix for each wall using SVM




그림 12. CNN-4를 통한 각 벽체에 대한 오차 행렬
Fig. 12. Confusion matrix for each wall using CNN-4




그림 13. ResNet-18를 통한 각 벽체에 대한 오차 행렬
Fig. 13. Confusion matrix for each wall using ResNet-18

표 2. ResNet-18을 이용한 안테나 배치별 정확도
Table 2. Accuracy by antenna array using ResNet-18

ResNet-18	Aluminium	Styrofoam	PVC
1 by 1	96.10%	99.13%	97.03%
3 by 3	98.87%	99.87%	99.63%
6 by 6	99.60%	99.97%	99.87%




그림 14. 1개 쌍 안테나로 각 벽체에 대한 오차 행렬 (ResNet-18)
Fig. 14. Confusion matrix for each wall using 1 by 1 Antenna(ResNet-18)




그림 15. 3개 쌍 안테나로 각 벽체에 대한 오차 행렬 (ResNet-18)
Fig. 15. Confusion matrix for each wall using 3 by 3 Antenna(ResNet-18)

표 3. CNN-4를 이용한 안테나 배치별 정확도
Table 3. Accuracy by antenna array using CNN-4

CNN-4	Aluminium	Styrofoam	PVC
1 by 1	74.20%	98.17%	78.10%
3 by 3	85.23%	99.53%	81.13%
6 by 6	88.23%	99.74%	82.41%

폼일 때의 물체 분류 정확도는 안테나 배치 구성과는 관계없이 정확도가 일정하게 높음을 확인할 수 있었다.

[표 2]와 [표 3]을 참고하여 알 수 있는 점으로, CNN-4 모델은 RF 신호에 대해 충분치 못한 합성곱 계층으로 인해 학습이 완전하지 않은 모습을 보이며, 이에 반해 ResNet-18 모델은 충분한 학습으로 인해 높은 정확도를 도출한다고 다시 한번 확인할 수 있다.




그림 16. 1개 쌍 안테나로 각 벽체에 대한 오차 행렬 (CNN-4)
Fig. 16. Confusion matrix for each wall using 1 by 1 Antenna(CNN-4)




그림 17. 3개 쌍 안테나로 각 벽체에 대한 오차 행렬 (CNN-4)
Fig. 17. Confusion matrix for each wall using 3 by 3 Antenna(CNN-4)

또한 [표 3]에서 알루미늄과 PVC 벽체에 대한 RF 신호에 대해 학습이 덜된 모습을 보이는데, 이는 RF 신호가 각각 알루미늄과 PVC 벽체를 통과할 때 투과율 및 반사율의 영향으로 인해 RF 신호에 측정 물체에 대한 정보량이 부족하다고 볼 수 있다. 반면 스티로폼 벽체에 대한 RF 신호는 소재에 따른 반사율이 비교적 높지 않기 때문에, RF 신호가 측정 물체에 대한 정보의 손실이 높지 않아 적은 안테나 개수로 배열을 구성하거나 충분치 못한 학습으로도 높은 정확도를 도출한다고 볼 수 있다.

V. 결론

본 논문에서는 IR-UWB 레이더 시스템과 MIMO 안테나 구성을 통해 생성된 RF 신호로 비가시 공간 내부의 물체의 정보를 수집하고, 해당 신호를 기계학습과 딥러닝의 물체 분류 학습 모델의 입력값으로 적용하여 물체 분류 정확도를 출력하였다. 이때, 비가시 공간을 구성하는 벽체의 소재별, MIMO 안테나 구성별, 그리고 물체 분류 모델별로 물체 분류를 진행하여 결과를 비교·분석하였다.

해당 실험의 학습 결과를 통해 확인할 수 있는 점으로는 벽체의 소재에 따라 물체 분류 결과에 영향을 미친다는 점인데, 이는 소재가 달라짐에 따라 RF 신호의 반사율 및 투과율이 달라져 신호의 측정 물체에 대한 정보량에 차이가 발생한다는 점을 확인하였다. 또한, 안테나 배치 구성의 차이로 인해 물체 분류 정확도 또한 차이가 발생함을 볼 수 있고, 이는 MIMO 구성을 통해 물체 정보에 대한 해상도 차이가 발생하여 RF 신호의 측정 물체에 대한 정보량에서도 차이가 발생한다는 점을 해당 실험을 통해 확인할 수 있었다. 추가로 물체 분류 모델에 차이를 두어, 학습을 진행했을 때 딥러닝을 통해 물체의 해상도 차이를 극복하고 물체 분류 정확도를 높일 수 있다는 결과를 도출하였다.

본 논문에서는 비가시 공간이라는 특수한 환경을 구성하는 벽체의 종류가 적다는 점과 세 가지의 측정 물체가 단일 종류인 점에서 성능의 일반화에 대한 한계점이 존재한다. 그러나 다양한 MIMO 안테나 배열을 구성하여 비가시 공간을 구성하는 장애물로 인해 발생하는 RF 신호의 정보 손실을 보상하고, 안테나 배열에 따른 측정 물체에 대한 해상도 차이를 통해 RF 신호의 정보량에 차이가 있다는 점을 물체 분류 결과를 통해 확인할 수 있었다. 또한, RF 신호를 입력값으로 받는 물체 분류 모델에 변경하면서 결과를 출력하여, 제한된 정보량을 지닌 RF 신호임에도 정교한

학습 모델을 통해 높은 성능을 보일 수 있음을 본 논문의 실험을 통해 확인하였다.

이를 통해 비가시 공간에서 같은 물체의 정보가 저장된 RF 신호에 대해서 벽체의 소재별로 발생한 정보 손실로 인한 성능 차이를 고려하여, 비가시 영역에서의 물체 탐지 기술에 적용하여 성능에 대한 일반화를 기대할 수 있다. 또한, 비가시 공간에서의 측정 물체에 대한 정보 손실을 최소화하는 MIMO 안테나 배열 구성에 대한 후속 연구도 기대해볼 수 있다. 추가로, 많은 레이더 안테나 개수를 통해 안테나 배열을 구성하면 높은 성능을 보일 수 있지만, 레이더 안테나의 비용이 많이 든다는 점과 해당 안테나 배열을 배치할 넓은 공간이 필요하게 된다. 이러한 비용 및 공간적으로 제한된 상황에서도 충분한 성능을 출력하는 학습 모델 연구 또한 기대할 수 있다.

References

- [1] J. W. Lim, D. M. Seol, S. H. Jung, S. B. Lee, C. S. Lee, and S. M. Chung, "Performance analysis of IR-UWB based indoor positioning device," in *Proc. Symp. KICS*, pp. 987-988, Jeju Island Korea, 2020.
- [2] V.-H. Nguyen and J. Y. Pyun, "Location detection and tracking of moving targets by a 2D IR-UWB radar system," *Sensors*, vol. 15, no. 3, pp. 6740-6762, 2015. (<https://doi.org/10.3390/s150306740>)
- [3] F. Adib, et al., "3D tracking via body radio reflections," *11th USENIX Symp. NSDI 14*, pp. 317-329, 2014.
- [4] F. Adib, Z. Kabelac, and D. Katabi, "Multi-person motion tracking via RF body reflections," in *Proc. Usenix NSDI*, 2015.
- [5] F. Adib, et al., "Capturing the human figure through a wall," *ACM Trans. Graphics (TOG)*, vol. 34, no. 6, pp. 1-13, 2015. (<https://doi.org/10.1145/2816795.2818072>)
- [6] M. Zhao, et al., "Through-wall human pose estimation using radio signals," in *Proc. IEEE Conf. CVPR*, pp. 7356-7365, 2018. (<https://doi.org/10.1109/CVPR.2018.00768>)
- [7] T. Li, et al., "Making the invisible visible: Action recognition through walls and occlusions," in *Proc. IEEE/CVF Int. Conf. Computer Vision*, pp. 872-881, 2019. (<https://doi.org/10.48550/arxiv.1909.09300>)
- [8] M. Zhao, et al., "Through-wall human mesh recovery using radio signals," in *Proc. IEEE/CVF Int. Conf. Computer Vision*, pp. 10113-10122, 2019. (<https://doi.org/10.1109/ICCV.2019.01021>)
- [9] I. I. Immoreev and PGS D. V. Fedotov, "Ultra wideband radar systems: advantages and disadvantages," *2002 IEEE Conf. Ultra Wideband Syst. and Technol. (IEEE Cat. No. 02EX580)*, pp. 201-205, 2002. (<https://doi.org/10.1109/UWBST.2002.1006348>)
- [10] Z. Hu, et al., "Design and analysis of a UWB MIMO radar system with miniaturized Vivaldi antenna for through-wall imaging," *Remote Sensing*, vol. 11, no. 16, 2019. (<https://doi.org/10.3390/rs11161867>)
- [11] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *ACM Communications of the ACM*, vol. 60, issue. 6, pp. 84-90, 2017. (<https://doi.org/10.1145/3065386>)
- [12] K. He, et al., "Deep residual learning for image recognition," in *Proc. IEEE Conf. CVPR*, pp. 770-778, 2016. (<https://doi.org/10.1109/CVPR.2016.90>)

이 상 원 (Sang-Won Lee)



2021년 2월 : 성균관대학교 전자전기공학과 학사 졸업
2021년 3월~현재 : 성균관대학교 전자전기컴퓨터공학과 석사과정
<관심분야> 레이더, 머신러닝
[ORCID:0000-0001-8837-3255]

최 계 원 (Kae-Won Choi)



2007년 8월 : 서울대학교 전기컴퓨터공학부 박사
2010년 9월~2016년 8월 : 서울과학기술대학교 컴퓨터공학과 조교수
2016년 9월~현재 : 성균관대학교 전기전자컴퓨터공학과 부교수
<관심분야> 무선통신, 무선전력전송
[ORCID:0000-0002-3680-1403]