

# FMCW 레이다 기반의 포인트 클라우드와 LSTM을 이용한 자동 핸드 제스처 영역 추출 및 인식 기법

## Automatic hand gesture area extraction and recognition technique using FMCW radar based point cloud and LSTM

라 승 탁\*, 이 승 호\*

Seung-Tak Ra\*, Seung-Ho Lee\*

### Abstract

In this paper, we propose an automatic hand gesture area extraction and recognition technique using FMCW radar-based point cloud and LSTM. The proposed technique has the following originality compared to existing methods. First, unlike methods that use 2D images as input vectors such as existing range-dopplers, point cloud input vectors in the form of time series are intuitive input data that can recognize movement over time that occurs in front of the radar in the form of a coordinate system. Second, because the size of the input vector is small, the deep learning model used for recognition can also be designed lightly. The implementation process of the proposed technique is as follows. Using the distance, speed, and angle information measured by the FMCW radar, a point cloud containing x, y, z coordinate format and Doppler velocity information is utilized. For the gesture area, the hand gesture area is automatically extracted by identifying the start and end points of the gesture using the Doppler point obtained through speed information. The point cloud in the form of a time series corresponding to the viewpoint of the extracted gesture area is ultimately used for learning and recognition of the LSTM deep learning model used in this paper. To evaluate the objective reliability of the proposed technique, an experiment calculating MAE with other deep learning models and an experiment calculating recognition rate with existing techniques were performed and compared. As a result of the experiment, the MAE value of the time series point cloud input vector + LSTM deep learning model was calculated to be 0.262 and the recognition rate was 97.5%. The lower the MAE and the higher the recognition rate, the better the results, proving the efficiency of the technique proposed in this paper.

### 요 약

본 논문에서는 FMCW 레이다 기반의 포인트 클라우드와 LSTM을 이용한 자동 핸드 제스처 영역 추출 및 인식 기법을 제안한다. 제안한 기법은 기존의 방식과 다른 다음과 같은 독창성이 있다. 첫 번째, 기존의 range-doppler 등의 2D 이미지를 입력 벡터로 하는 방식과 다르게 시계열 형태의 포인트 클라우드 입력 벡터는 레이다 전방에서 발생하는 시간에 따른 움직임을 좌표계 형태로 인식할 수 있는 직관적인 입력 데이터이다. 두 번째, 입력 벡터의 크기가 작기 때문에 인식에 쓰이는 딥러닝 모델도 가볍게 설계할 수 있다. 제안하는 기법의 수행 과정은 다음과 같다. FMCW 레이다로 측정된 거리, 속도, 각도 정보를 활용해 x, y, z 좌표 형식과 도플러 속도 정보를 포함한 포인트 클라우드를 활용한다. 제스처 영역은 속도 정보를 통해 얻어진 도플러 포인트를 이용하여 제스처의 시작과 끝 지점을 파악해 자동으로 핸드 제스처 영역을 추출하게 된다. 추출된 제스처 영역의 시점에 해당하는 시계열 형태의 포인트 클라우드는 최종적으로 본 논문에서 사용한 LSTM 딥러닝 모델의 학습 및 인식에 활용되게 된다. 제안하는 기법의 객관적인 신뢰성을 평가하기 위해 다른 딥러닝 모델들과 MAE를 산출하는 실험과 기존 기법들과 인식률을 산출하는 실험을 수행하여 비교하였다. 실험 결과, 시계열 형태의 포인트 클라우드 입력 벡터 + LSTM 딥러닝 모델의 MAE 값이 0.262, 인식률이 97.5%로 산출되었다. MAE는 낮을수록, 인식률은 높을수록 우수한 결과를 나타내므로 본 논문에서 제안한 기법의 효율성이 입증되었다.

*Key words : FMCW Radar, Point Cloud, LSTM, Hand Gesture Area Extraction, Hand Gesture Recognition*

## I. 서론

최근 다양한 센서 기반의 제스처 인식[1]은 자동차, 인간-컴퓨터 상호 작용, 로봇 공학 및 의료를 포함한 다양한 분야에서 실용적으로 응용되는 연구 분야로 성장하고 있다. 제스처 인식의 최대 장점은 비접촉식 상호 작용이라는 점이며 이는 바이러스 확산을 방지해야 하는 의료 관련 환경이나 전방 주시가 강요되어 장치나 표면을 만지는 것이 바람직하지 않은 차량 내 운전자[2]의 환경과 같은 곳에서 특히 유용하다. 특히 레이더 센서는 기존 제스처 인식에 주로 쓰이는 카메라나 depth 센서에 비해 조명과 같은 환경 조건에 영향을 안 받는다는 점과 시각적 이미지를 캡처하지 않기에 프라이버시를 침해하지 않는 점, 여러 연구 결과를 통해 입증된 높은 제스처 인식률을 가질 수 있다는 여러 장점들이 있기에 레이더 센서 기반의 제스처 인식의 연구는 필수적이라 할 수 있다.

FMCW(Frequency Modulated Continuous Wave) 레이더는 전방 물체의 거리, 속도, 각도 등의 다양한 정보를 얻을 수 있다. 기존의 딥러닝을 활용한 제스처 인식 [3][4]의 경우, 이러한 정보들로 2D 이미지를 만든 후 CNN 등의 딥러닝과 결합하여 제스처 인식을 수행하였다. 딥러닝 모델의 특성상 입력 벡터 크기가 고정되어야 하기에 학습 data를 만들 시, 제한된 시간 안에 실험자가 제스처를 취하여 고정된 크기의 data를 취득하게 된다. 이러한 data의 경우 제스처의 시작과 끝 지점은 알 수 없지만 특정 시간 안에 무조건 제스처가 1번 취해진다는 가정이 있기에 학습에 최적화된 data라 할 수 있다. 하지만 실제 산업현장의 환경을 고려한다면 제스처 인식의 시간은 사람마다 다를 수 있으며, 특히 제스처를 시작하는 시점과 끝내는 시점을 알아야 실시간으로 제스처 인식을 수행할 수 있다. 또한 CNN 등의 딥러닝 모델

은 필요 자원의 크기가 크기에 산업현장의 임베디드 보드 환경에서 동작함에 있어 제약사항이 있을 수 있다.

따라서 본 논문에서는 실시간 도플러 포인트를 이용하여 제스처의 시작과 끝을 알아낸 뒤 제스처 영역을 추출하고, 포인트 클라우드와 LSTM을 이용하여 추출된 제스처 영역을 인식하는 FMCW 레이더 기반의 포인트 클라우드와 LSTM을 이용한 자동 핸드 제스처 영역 추출 및 인식 기법을 제안한다.

## II. 본론

### 1. 전체 개요

본 논문에서 제안하는 FMCW 레이더 기반의 포인트




Fig. 1. A complete overview of the proposed method in this paper.

그림 1. 본 논문에서 제안한 기법의 전체 개요도

\* Dept. Electronic Engineering, Hanbat National University

★ Corresponding author

E-mail : shlee@cad.hanbat.ac.kr, Tel : +82-42-821-1137

※ Acknowledgment

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT)(No. NRF-2022R1F1A1066371)

This results was supported by "Regional Innovation Strategy (RIS)" through the National Research Foundation of Korea(NRF) funded by the Ministry of Education(MOE)(2021RIS-004)

This research was supported by the MSIT (Ministry of Science and ICT), Korea, under the ICAN (ICT Challenge and Advanced Network of HRD) program (IITP-2022-RS-2022-00156212) supervised by the IITP (Institute of Information & Communications Technology Planning & Evaluation)

Manuscript received Nov. 28, 2023, revised Dec. 12, 2023, accepted Dec. 15, 2023

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

클라우드와 LSTM을 이용한 자동 핸드 제스처 영역 추출 및 인식 기법의 전체 개요도는 그림 1과 같다. 첫 번째로, FMCW 레이더를 이용하여 거리, 속도, 각도 정보를 측정한다. 두 번째로, 측정된 거리, 속도, 각도 정보를 활용해 x, y, z 좌표 형식과 도플러 속도 정보를 포함한 포인트 클라우드를 획득한다. 세 번째로, 속도 정보를 통해 얻어진 도플러 포인트를 이용하여 핸드 제스처 영역을 추출한다. 마지막으로, 추출된 제스처 영역의 포인트 클라우드 정보를 이용해 최종적으로 핸드 제스처를 인식할 LSTM 모델을 학습하게 된다.

## 2. FMCW 레이더를 이용한 거리, 속도, 각도 측정

FMCW 레이더는 칩 신호를 전송하는 레이더이며, 칩 신호는 그림 2와 같이 시간에 따라 주파수를 증가시키는 신호를 뜻한다. 수신안테나를 통해 수신된 신호는 Mixer를 통해 IF 신호로 변환되며, Mixer에 입력되는 두 입력을  $x_1, x_2$ 라 하고, 출력을  $x_{out}$ 이라 한다면, 각 변수를 나타내는 식은 식(1)~(3)과 같다. 식에서  $w$ 는 주파수고  $\theta$ 는 위상을 나타낸다. Mixer를 통해 얻은 IF 신호를 처리하면 전방의 물체에 대한 여러 정보를 얻을 수 있다.




Fig. 2. Chirp signal from FMCW radar.  
그림 2. FMCW 레이더의 칩 신호

$$x_1 = \sin(w_1 t + \theta_1) \quad (1)$$

$$x_2 = \sin(w_2 t + \theta_2) \quad (2)$$

$$x_{out} = \sin[(w_1 - w_2)t + (\theta_1 - \theta_2)] \quad (3)$$

### 2.1 거리 측정

만약 레이더 앞에 단일 물체가 있다면 그림 3과 같은 IF 신호를 생성하며  $\tau$ 는 레이더와 물체 사이의 왕복 시간을 나타내고  $S_\tau$ 는 칩의 기울기를 나타낸다. 따라서 레이더 앞에 있는 단일 물체는 일정한 주파수의 IF 신호를 생성하며 이 주파수는  $S_\tau = S^2 d/c$ 로 표현된다. ( $d$  = 물체의 거리,  $c$  = 빛의 속도). IF 신호를 FFT하면  $S_\tau$ 의 주

파수를 알 수 있으므로 레이더 앞의 물체와의 거리는 식 (4)를 통해 계산되게 된다.

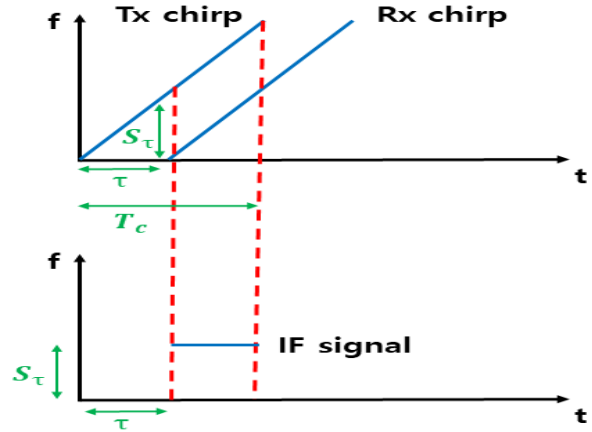


Fig. 3. Calculation of distance between radar and object using IF signal.

그림 3. IF 신호를 통한 레이더와 물체 간의 거리 계산

$$d = \frac{S_\tau c}{2S} \quad (4)$$

### 2.2 속도 측정

FMCW 레이더는 지속적으로 칩 신호를 송수신하며, 속도는 두 번의 칩을 사용하여 구할 수 있다. 거리의 작은 변화는 위상차를 발생시키며, 그림 4와 같이  $T_c$ 로 분리된 두 개의 칩을 전송하면 각 칩에 해당하는 거리-FFT의 결과는 동일한 위치에서 피크를 나타낸다. 하지만 위상이 다르기에 위상차( $\omega$ )를 구할 수 있고, 이를 이용해 식(5)와 같이 속도를 구할 수 있다.

$$\omega = \frac{4\pi v T_c}{\lambda}, \quad v = \frac{\lambda \omega}{4\pi T_c} \quad (5)$$

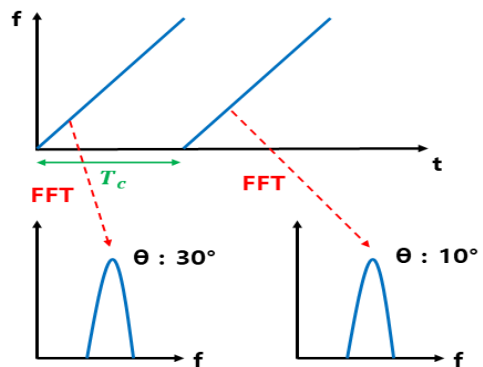


Fig. 4. Speed measurement using phase difference between signals.

그림 4. 칩 신호 간의 위상차를 이용한 속도 측정

2.3 각도 측정

2개의 RX 안테나가 있다면 그림 5와 같이 안테나 사이의 거리  $d$ 에 따라 각 안테나의 2D-FFT는 동일한 위치에서 위상이 다른 피크를 갖게되며, 측정된 위상차( $\omega$ )를 사용하여 물체와의 각도를 추정할 수 있다[5]. 각도를 계산하는 식은 식(6)~(7)과 같다.




Fig. 5. Angle measurement using phase difference between Rx.

그림 5. Rx 간의 위상차를 이용한 각도 측정

$$\omega = \frac{2\pi d \sin(\theta)}{\lambda} \tag{6}$$

$$\theta = \sin^{-1}\left(\frac{\lambda \omega}{2\pi d}\right) \tag{7}$$

3. 측정된 정보를 이용한 포인트 클라우드 획득

IF신호는 Tx \* Rx의 수만큼 수신되며 그림 6은 1Tx, 4Rx일 경우 형성되는 3차원 큐브 형태를 나타낸다. N은 첩 신호를 ADC 샘플링하는 수이고, P는 프레임당 첩의 수를 나타낸다. 만약 그림 6과 같이 x, y, z 방향을 정의한다면 FMCW 레이다가 수신된 한 번의 첩을 ADC 한다는 것은 x, y 평면에 해당하는 큐브 단면 정보를 얻을 수 있다는 것을 의미한다. 또한 FMCW 레이다가 지속적

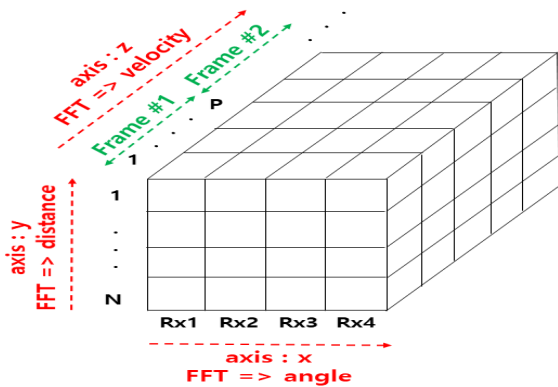


Fig. 6. 3D cube information formed by FMCW radar.

그림 6. FMCW 레이다가 형성하는 3차원 큐브 정보

으로 수신되는 첩을 ADC 샘플링 한다면 z 방향으로 3차원 큐브가 쌓이게 된다는 것을 의미한다. FMCW 레이다는 지속적으로 3차원 큐브를 3방향으로 CFAR(Constant False Alarm Rate)등의 신호 처리 과정을 포함하여 FFT 하면서 거리, 속도, 각도 정보를 측정하게 된다.

본 논문에서 사용한 FMCW 레이다의 안테나 수는 3Tx, 4Rx이며 Rx가 2x2 배열 형태이기에 수평과 수직에 대한 각도를 알 수 있다. 따라서, 레이다로 측정된 거리(d), 각도 정보로 식 (8)~(10)을 이용하여 x, y, z 좌표 형식의 3차원 포인트 클라우드를 획득할 수 있고 그림 7은 예시를 나타낸다. 추가적으로 각 포인트 클라우드에는 도플러 속도 정보까지 추가하여 본 논문에서 사용하는 포인트 클라우드는 4차원 정보이다. 도플러 속도는 현재 측정된 포인트가 레이다와 가까워지는 중인지, 멀어지는 중인지에 대한 정보를 포함하고 있기에 제스처 인식에 중요한 요소가 된다.

$$x = d \times \sin(Azimuth(\theta)) \times \cos(Elevation(\theta)) \tag{8}$$

$$y = d \times \cos(Azimuth(\theta)) \times \sin(Elevation(\theta)) \tag{9}$$

$$z = d \times \sin(Elevation(\theta)) \tag{10}$$




Fig. 7. Point cloud example.

그림 7. 포인트 클라우드 예시

4. 도플러 포인트를 이용한 핸드 제스처 영역 추출

도플러 포인트는 측정된 포인트 클라우드에서 도플러 속도가 0이 아닌 포인트의 수를 모두 더하여 구할 수 있다. 도플러 포인트는 현재 레이다 전방에 움직임이 얼마나 있는지를 수치적으로 나타내는 지표이다. 만약 레이다 전방에 제스처가 한번 취했다면 그림 8과 같이 도플러 포인트의 수는 급하게 증가하였다가 떨어지는 그래프의 경향을 보이게 된다. 도플러 포인트 그래프의 곡선은 실제로 완만한 곡선의 형태를 보이지 않기에 평균 필터를 적용하였다. 특정 임계값을 기준으로 정하고 지속적으로 도플러 포인트의 수를 측정한다면 제스처의 시작과 끝을 알 수 있기에 자동으로 핸드 제스처 영역을 추출할 수 있다. 핸드 제스처 영역이 추출되었다면 시작과

끝 지점에 해당하는 시간의 포인트 클라우드 정보가 최종적으로 LSTM 모델의 학습과 인식에 쓰이게 된다. 포인트 클라우드는 칩 신호를 한번 처리할 때마다 여러 개가 측정되지만 본 논문에서는 그 중, 레이더와 거리가 가장 가까운 포인트 하나만을 선별하여 사용하였다.

한편, 본 논문에서는 제스처가 레이더와 근접하게 취해진다는 가정을 두고, 레이더 전방의 1m 내에 해당하는 영역의 도플러 포인트만 사용하였다. 그 이유로는 만약 모든 영역의 도플러 포인트를 사용할 경우, 레이더와 먼 거리의 도플러 속도까지 포함되기에 제스처 영역 추출의 오류가 있을 수 있기 때문이다.




Fig. 8. Hand gesture area extraction using doppler points.  
그림 8. 도플러 포인트를 이용한 핸드 제스처 영역 추출

### 5. 포인트 클라우드를 이용한 LSTM 모델 학습

LSTM(Long Short-Term Memory)은 시계열 데이터의 예측에 주로 쓰이는 딥러닝 모델[6]이다. LSTM은 RNN(Recurrent Neural Network)의 Gradient Vanishing 문제를 해결하기 위해 고안된 모델이며 이전 정보를 오랫동안 기억할 수 있는 메모리 셀을 가지고 있어 긴 입력 데이터를 처리할 수 있다.

본 논문에서의 레이더 처리 속도는 10fps이고, 한 번의 제스처가 실험자에 따라 다르겠지만 늦어도 최대 0.8초가 걸리는 것을 확인하여, 시퀀스 8의 시계열 포인트 클라우드 정보를 LSTM 모델의 학습에 사용하였다. 0.8초보다 빠르게 취해진 제스처 영역은 제로 패딩으로 나머지 영역을 채웠고, 느린 제스처 영역은 다운 샘플링하여 0.8초에 해당하는 영역으로 변환하였다. 칩 신호 1회 처리마다 여러 개의 포인트 클라우드 중 가장 레이더와 거리가 가까운 하나가 선별되고, 포인트 클라우드는 x, y, z, 도플러 속도 총 4개 종류의 data를 가지고 있기에 0.1초에 해당하는 입력 벡터는 1×4이다. 따라서 LSTM 모델 학습에 쓰이는 0.8초의 제스처 영역의 시계열 입력

벡터는 1×4의 입력 벡터가 시퀀스 8로 차례대로 8번 입력에 들어가는 구조이다. 이러한 시계열 형태의 포인트 클라우드는 LSTM의 학습에 쓰이게 되며, 최종적으로 학습된 모델은 그림 9와 같이 핸드 제스처 인식에서 활용된다.

우선 사용자가 제스처를 취하게 되면 레이더로부터 측정되는 정보로부터 포인트 클라우드를 획득한다. 레이더에서 측정되는 거리, 속도, 각도 정보는 x, y, z, 도플러 속도 형태의 포인트 클라우드로 도출될 수 있다. 그 후, 도플러 포인트를 이용하여 추출된 제스처 영역에 해당하는 포인트 클라우드를 LSTM 모델의 입력으로 넣게 된다. 입력으로 들어가는 포인트 클라우드는 제스처의 시작과 끝 지점에 해당하기에 시계열 형태의 포인트 클라우드가 된다. 마지막으로 시계열 형태의 포인트 클라우드 입력으로부터 얻어진 LSTM의 출력 값에 따라 핸드 제스처가 어떤 결과인지 인식하게 된다.




Fig. 9. The entire hand gesture recognition process.  
그림 9. 전체 핸드 제스처 인식 과정

본 논문에서의 LSTM 모델 구조는 하나의 LSTM 입력과 은닉, 출력 총 3개의 레이어로 구성되었으며 은닉 레이어와 출력 레이어의 차원은 각각 10, 1로 구성하였다. 손실 함수(Loss function)는 MSE를 사용하였고, 옵티마이저는 Adam을 사용하였다. 학습률은 0.0001, Epoch




Fig. 10. Loss graph according to Epoch.  
그림 10. Epoch에 따른 loss 그래프

은 500번으로 설정하였다. 데이터의 경우, 전체 데이터 10을 기준으로 8 : 2(학습 : 테스트)로 분배하였다. 그림 10은 학습 과정에서의 loss를 나타낸 그래프이다.

6. 성능 실험

가. 실험 환경

실험에 사용된 PC의 운영체제 및 하드웨어는 Windows 10 64비트 운영체제를 기반으로 Intel(R) Core(TM) i7-10700k 3.8GHz CPU, RAM 16GB, NVIDIA GeForce RTX 3070 (VRAM 8GB) GPU로 구성되어 있다. 개발 도구는 Visual Studio Code와 Pytorch 1.9.1, CUDA 11.1, cuDNN 8.2.1 라이브러리를 사용하였다. 레이더의 하드웨어는 Texas Instruments 사의 IWR6843 ISK-ODS이며 최대 탐지 거리 2.41m, 거리 해상도 0.047m, 최대 탐지 속도 1m/s, 속도 해상도 0.07m/s를 만족하도록 칩 파형을 설계하였다. 데이터의 경우 실험자들이 그림 11과 같이 총 4가지의 핸드 제스처를 50번씩 수행하여 200개의 데이터를 구축하였으며 테스트는 20%인 40개로 평가하였다.




Fig. 11. Four hand gestures used in the experiment. 그림 11. 실험에 사용한 4가지 핸드 제스처

나. 실험 결과

제안하는 기법인 시계열 형태의 포인트 클라우드 입력 벡터와 가장 적합한 딥러닝 모델을 평가하기 위하여 표 1에서 딥러닝 모델들과의 MAE를 비교하였다. 표 1의 1, 2번[7] 딥러닝 모델은 입력 벡터에 1D Convolution을 적용하여 feature map을 얻는 과정까지는 동일하며, 필터 크기는 3, stride는 1, 채널 수는 16으로 설정하였다. 1번 모델은 Convolution 출력 채널 수에 맞게 노드를 설정하여 은닉 레이어와 출력 레이어 각 1개씩으로 구성되었다. 2번 모델은 Convolution 출력 채널 수에 맞게 3번과 동일한 LSTM 레이어를 추가한 딥러닝 모델이다. 표 1의 딥러닝 모델들은 regression 딥러닝 모델이며 평가지표에 사용된 MAE(Mean Absolute Error)는 regression 딥러닝 모델에 주로 쓰이는 평가지표이다. 분류 문제인 제스처 인식에 regression 모델을 사용한

이유는 인식률은 동일한 수치가 나올 수 있기에 제안하는 기법과 가장 적합한 모델을 찾기에 부적합하다고 판단하였다. regression 딥러닝 모델로 설계한다면 MAE를 산출할 수 있으며, MAE는 적합성을 판단하기에 좋은 정량적 수치를 제공하는 지표이다. MAE는 수치가 낮을수록 우수함을 나타내며 실험 결과, 본 논문에서 제안하는 기법인 시계열 형태의 포인트 클라우드 + LSTM 모델이 다른 모델들보다 우수한 것이 확인되었다. 즉, 시계열 형태의 입력 벡터 정보 특징을 가장 많이 활용한 LSTM 모델이 더욱 우수한 결과를 나타낸 것으로 사료된다. 그림 12는 표 1에서 사용된 모델들의 test set 예측 그래프이며, 제스처 종류에 따라 0, 3, 6, 9로 라벨링된 참값을 예측하는 것을 보여준다. MAE가 가장 낮은 LSTM이 참 값과 가장 비슷한 예측을 하고 있는 것을 나타낸다.

Table 1. MAE comparison results with deep learning models.

표 1. 딥러닝 모델들과의 MAE 비교 결과

No	Method	MAE ↓
1	Point cloud + 1D-CNN	0.794
2	Point cloud + 1D-CNN-LSTM	0.348
3	The proposed method (Point cloud + LSTM)	0.262




Fig. 12. Test set prediction graph for each model. 그림 12. 각 모델의 test set 예측 그래프

제안하는 기법인 시계열 형태의 포인트 클라우드 입력 벡터의 객관적인 성능을 평가하기 위해 표 2에서 기존 기법들과 핸드 제스처 인식률을 비교하였다. 실험에 쓰인 2D 이미지는 제스처 인식에 주로 쓰이는 range-doppler 이미지[8]이다. 평가 지표로는 인식률을 사용하였으며 테스트 데이터에서 정답을 맞춘 비율을 나타낸다. 실험 결과, 본 논문에서 제안하는 기법인 시계열 형태의 포인트 클라우드 + LSTM이 다른 기법들보다 우수한 인식률을 나타내었다.

Table 2. Comparison results of hand gesture recognition rates with existing techniques.

표 2. 기존 기법들과의 핸드 제스처 인식을 비교 결과

No	Method	Recognition ↑
1	Range-doppler image + 2D-CNN	75%
2	Point cloud + 1D-CNN	72.5
3	Point cloud + 1D-CNN-LSTM	92.5
4	The proposed method (Point cloud + LSTM)	97.5%

### III. 결론

본 논문에서는 FMCW 레이더 기반의 포인트 클라우드와 LSTM을 이용한 자동 핸드 제스처 영역 추출 및 인식 기법을 제안하였다. 제안한 기법은 기존의 방식과 다른 다음과 같은 독창성이 있다. 첫 번째, 기존의 range-doppler 등의 2D 이미지를 입력 벡터로 하는 방식과 다르게 시계열 형태의 포인트 클라우드 입력 벡터는 레이더 전방에서 발생하는 시간에 따른 움직임을 좌표계 형태로 인식할 수 있는 직관적인 입력 데이터이다. 두 번째, 입력 벡터의 크기가 작기 때문에 인식에 쓰이는 딥러닝 모델도 가볍게 설계할 수 있다. 제안하는 기법의 수행 과정은 다음과 같다. FMCW 레이더로 측정된 거리, 속도, 각도 정보를 활용해 x, y, z 좌표 형식과 도플러 속도 정보를 포함한 포인트 클라우드를 활용한다. 제스처 영역은 속도 정보를 통해 얻어진 도플러 포인트를 이용하여 제스처의 시작과 끝 지점을 파악해 자동으로 핸드 제스처 영역을 추출하게 된다. 추출된 제스처 영역의 시점에 해당하는 시계열 형태의 포인트 클라우드는 최종적으로 본 논문에서 사용한 LSTM 딥러닝 모델의 학습 및 인식에 활용되게 된다. 제안하는 기법의 객관적인 신뢰성을 평가하기 위해 다른 딥러닝 모델들과 MAE를 산출하는 실험과 기존 기법들과 인식률을 산출하는 실험을 수행하여 비교하였다. 실험 결과, 시계열 형태의 포인트 클라우드 입력 벡터 + LSTM 딥러닝 모델의 MAE 값이 0.262, 인식률이 97.5%로 산출되었다. MAE는 낮을수록, 인식률은 높을수록 우수한 결과를 나타내므로 본 논문에서 제안한 기법의 효율성이 입증되었다.

향후 연구과제로는 포인트 클라우드에 제스처 인식에 더욱 적합한 추가적인 정보를 더하여 기존보다 더욱 정교한 입력 데이터를 만드는 과정을 통해 제스처 인식률을 향상시킬 수 있는 연구가 필요하다.

### References

- [1] Mitra, Sushmita, and Tinku Acharya. "Gesture recognition: A survey." *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)* 37.3, 311-324, 2007. DOI: 10.1109/TSMCC.2007.893280
- [2] Molchanov, Pavlo, et al. "Multi-sensor system for driver's hand-gesture recognition." *2015 11th IEEE international conference and workshops on automatic face and gesture recognition (FG)*. Vol.1. IEEE, 2015. DOI: 10.1109/FG.2015.7163132
- [3] Franceschini, S., et al. "Hand gesture recognition via radar sensors and convolutional neural networks." *2020 IEEE Radar Conference (RadarConf20)*. IEEE, 2020. DOI: 10.1109/RadarConf2043947.2020.9266565
- [4] Wu, Qisong, and Dixian Zhao. "Dynamic hand gesture recognition using FMCW radar sensor for driving assistance." *2018 10th International Conference on Wireless Communications and Signal Processing (WCSP)*. IEEE, 2018. DOI: 10.1109/WCSP.2018.8555642
- [5] Skaria, Sruthy, et al. "Hand-gesture recognition using two-antenna Doppler radar with deep convolutional neural networks." *IEEE Sensors Journal* 19.8, 3041-3048, 2019. DOI: 10.1109/JSEN.2019.2892073
- [6] Yu, Yong, et al. "A review of recurrent neural networks: LSTM cells and network architectures." *Neural computation* 31.7, 1235-1270, 2019. DOI: 10.1162/neco\_a\_01199
- [7] Shen, Zhipeng, et al. "SeriesNet: a generative time series forecasting model." *2018 international joint conference on neural networks (IJCNN)*. IEEE, 2018. DOI: 10.1109/IJCNN.2018.8489522
- [8] Hazra, Souvik, and Avik Santra. "Short-range radar-based gesture recognition system using 3D CNN with triplet loss." *IEEE Access* 7: 125623-125633, 2019. DOI: 10.1109/ACCESS.2019.2938725

---

**BIOGRAPHY**

---

**Seung-Tak Ra** (Member)

2017 : BS degree in Electronic Engineering, Hanbat National University

2019 : MS degree in Electronic Engineering, Hanbat National University

2022~current : Ph. D degree course of Electronic Engineering Hanbat National University

**Seung-Ho Lee** (Member)

1986 : BS degree in Electronic Engineering, Hanyang University

1989 : MS degree in Electronic Engineering, Hanyang University

1994 : Ph. D degree in Electronic Engineering, Hanyang University

1994~current : Professor, Department of Electronic Engineering, Hanbat National University