

차량 도어 충돌 방지용 레이다 신호처리 시스템 설계 및 구현

Design and Implementation of Radar Signal Processing System for Vehicle Door Collision Prevention

한 정 우*, 김 민 상*, 김 대 홍*, 정 윤 호*

Jeongwoo Han*, Minsang Kim*, Daehong Kim*, Yunho Jung*

Abstract

This paper presents the design and implementation results of a Raspberry-Pi-based embedded system with an FPGA accelerator that can detect and classify objects using an FMCW radar sensor for preventing door collision accidents in vehicles. The proposed system performs a radar sensor signal processing and a deep learning processing that classifies objects into bicycles, automobiles, and pedestrians. Since the CNN algorithm requires substantial computation and memory, it is not suitable for embedded systems. To address this, we implemented a lightweight deep learning model, BNN, optimized for embedded systems on an FPGA, and verified the results achieving a classification accuracy of 90.33% and an execution time of 20ms.

요 약

본 논문에서는 차량의 개문사고를 예방하기 위한 목적으로 FMCW 레이다 센서를 활용하여 물체를 감지하고 분류 가능한 시스템 설계 및 구현 결과가 제시된다. 제안된 시스템은 Raspberry-Pi 기반 임베디드시스템과 FPGA 가속기에 기반하여 구현되었으며, 해당 시스템은 레이다 센서 신호처리 과정과 물체를 자전거, 자동차, 사람으로 분류하는 딥러닝 과정을 수행한다. CNN 알고리즘은 연산량과 메모리 사용량이 크기 때문에 임베디드시스템에 적합하지 않다. 이를 해결하기 위해 임베디드시스템에 적합한 경량화된 딥러닝 모델인 BNN을 FPGA 상에 구현한 뒤 결과를 검증하였고, 90.33%의 분류 정확도와 20ms의 수행시간을 확인하였다.

Key words : BNN Accelerator, FPGA, Embedded System, FMCW Radar, Object Detection

1. 서론

최근 자동차 시장의 규모는 꾸준히 증가하고 있으며, 차량 대수의 증가에 따라 정차한 차량의 문이 열리면서 발생하는 개문사고도 증가하는 추세이다. 이러한 개문사고는 탑승자와 보행자 모두에게 큰 위험을 초래하며, 심

각한 인명 피해로 이어질 수 있다. 따라서 개문사고를 예방하고 탑승객이 하차할 때에 편의성을 증진시킬 수 있는 시스템에 대한 수요가 급증하고 있다.

해당 시스템은 차량에 부착되어 낮은 전력으로 동작해야 하기 때문에, 소형화 및 경량화된 임베디드시스템을 통해 구현되어야 한다. 또한, 시스템 구현을 위해 카메

* School of Electronics and Information Engineering, Korea Aerospace University

★ Corresponding author

E-mail : yjung@kau.ac.kr, Tel : +82-2-300-0133

※ Acknowledgment

This work was supported by the Technology Innovation Program (No. 00144290, 00433615), funded by the Ministry of Trade, Industry and Energy (MOTIE, Korea) and CAD tools were supported by IDEC.

Manuscript received Sep. 11, 2024; revised Sep. 23, 2024; accepted Sep. 24, 2024.

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.

라, 라이다, 레이더 등 다양한 센서를 활용할 수 있으나, 이 중 카메라는 기상환경에 영향을 많이 받고, 라이다는 크기가 크고 가격이 비싸다. 반면, 레이더는 기상 환경에 영향을 거의 받지 않고, 가격과 크기 면에서 차량에 내장될 센서로 적합하다[1], [2].

레이더는 일정한 주파수를 연속적으로 방사하는 CW (Continuous Wave) 레이더 센서와 주파수가 시간에 따라 변조되는 신호를 연속적으로 방사하는 FMCW (Frequency Modulated Continuous Wave) 레이더 센서로 구분된다. CW 레이더 센서는 구조가 비교적 단순하지만 반사 신호의 시간 정보를 사용하지 않기 때문에 거리 측정이 불가능하여 해당 시스템을 구현하기에 부적합하다. 반면 FMCW 레이더 센서는 반사 신호의 주파수 변화를 이용하여 물체의 거리를 추가적으로 측정할 수 있고, 분해능이 높으며 다중 목표물이 구분 가능하다는 장점이 있다.

FMCW 레이더 센서를 사용해 취득한 데이터를 FFT (Fast Fourier Transform), CFAR(Constant False Alarm Rate), DBSCAN(Density-Based Spatial Clustering of Application with Noise), Tracking의 신호처리 과정을 거쳐 객체의 위치를 특정할 수 있게 되며, 해당 위치를 기준으로 도플러 성분을 추적하여 스펙트로그램을 생성할 수 있다.

획득한 스펙트로그램을 기반으로 딥러닝 기술의 일종인 CNN(Convolutional Neural Network) 알고리즘을 적용하면 객체를 높은 정확도로 구분할 수 있게 된다. 하지만 CNN은 높은 연산량과 많은 양의 메모리를 요구하기 때문에 데이터를 이진화하여 연산하는 BNN(Binarized Neural Network) 알고리즘이 실시간 동작 측면에서 유리하다[3].

레이더를 사용하여 개문사고를 방지하는 시스템에 대한 연구는 수행되었지만[4], 다가오는 객체를 분류하는 경우는 거의 없다. 본 연구에서 제안하는 BNN 가속기를 사용하여 후방에서 접근하는 물체를 실시간으로 분류할 수 있게 된다면, 각 상황의 위험성을 더 정확하게 파악하고 적절한 대처가 가능할 것으로 예상된다. 뿐만 아니라, 객체를 분류하는 기술은 더 나아가 자율주행에도 효과적으로 사용될 수 있을 것으로 기대된다.

본 논문의 구성은 다음과 같다. II장에서는 시스템에 사용된 기술에 대한 세부설명, III장에서는 실험상황에 대한 설명과 각 과정에 대한 성능평가에 관한 내용을 다루며, IV장에서는 결론을 맺는다.

II. Background

1. FMCW Radar

FMCW 레이더 센서는 기존의 CW 레이더에서 주파수가 변조된 연속파를 사용하는 레이더이다. 시간에 따라 선형적으로 변하는 삼각파 신호를 송신하고 목표물로부터 반사된 신호를 수신하게 된다. 수신된 신호와 송신된 신호 간 거리에 따른 주파수 차이인 비트 신호를 분석하여 거리 정보를 얻는다. T_{chirp} 만큼의 주파수 변조 시간을 갖고 이 구간을 chirp이라고 하는데 이러한 chirp들이 모여 하나의 프레임을 만들어낸다[5]. 그림 1은 FMCW 레이더의 신호 파형을 간략하게 나타내고 있다.

FMCW 레이더의 주요 특징은 매우 정밀한 거리 및 속도 측정이 가능하다는 점이다. 시간에 따라 변조된 신호는 목표물까지의 거리를 계산할 수 있을 뿐만 아니라, 도플러 효과에 의해 목표물의 속도까지 추정할 수 있다. 이는 움직이는 물체를 감지하는 데 유리하며, 정지된 물체와 이동 중인 물체를 구분하는 데에도 활용될 수 있다. 또한 FMCW 레이더는 주파수 변조 폭에 따라 분해능을 결정할 수 있어, 높은 주파수 대역을 사용할 경우 매우 정밀한 공간 분해능을 확보할 수 있다.

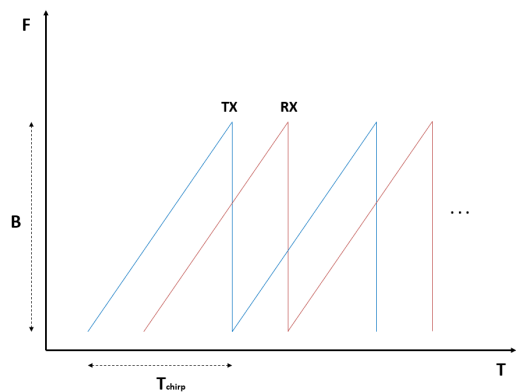


Fig. 1. FMCW radar transmission and reception signals.
그림 1. FMCW 레이더 송수신 신호

2. FFT

FFT는 시간 영역에서 얻은 신호를 주파수 영역으로 변환하여 신호의 주파수 성분을 분석하는 데 사용되는 중요한 기법이다. 이를 통해 복잡한 신호를 개별 주파수 성분으로 분해할 수 있어, 신호 속에 포함된 다양한 정보를 더욱 쉽게 추출할 수 있다. FMCW 레이더의 경우, 목표물로부터 반사된 신호의 주파수 차이를 분석하여 거리와 속도를 계산할 수 있는데, 이때 FFT는 필수적인 처리

과정이다.

1D FFT 방식을 두 번 적용하여 짧은 수행시간으로 비트 신호의 주파수 차이를 이용하여 물체의 속도와 거리를 측정할 수 있다. Chirp 내부의 샘플을 FFT하는 Range FFT 과정에서 목표의 거리 정보를 얻고, 그 결과를 프레임 단위로 누적하여 FFT하는 Doppler FFT 과정에서 목표의 속도 정보를 추출한다.

3. CFAR

CFAR는 표적 여부를 테스트하고자 하는 위치의 셀과 주변 셀의 관계를 보고 테스트 셀이 타겟인지 아닌지 구분하는 알고리즘이다. 여기서 테스트하고자 하는 셀을 CUT(Cell Under Test), 그리고 주변 셀을 reference cell이라고 하고, CUT와 reference cell 사이에는 guard cell이 존재하여 이 두 셀을 구분한다. Reference cell을 통해 threshold 값을 생성하고 CUT가 threshold 값보다 크면 타겟, 아니면 노이즈로 판단한다.

CFAR 알고리즘의 종류에는 여러 가지가 있는데 대표적으로 CA-CFAR(Cell Average CFAR), OS-CFAR(Ordered Static CFAR) 등이 존재한다. 제안된 시스템에서는 CA-CFAR를 사용하여 단일 표적에 대한 검출을 진행한다.

CA-CFAR는 reference cell의 평균에 scale factor (α)를 곱하여 threshold 값을 생성한다. Reference cell의 평균만을 계산하면 threshold를 구할 수 있으므로 연산량이 적고 구조가 간단하다. 사람과 자전거의 micro-Doppler를 보다 더 많이 잡아내기 위해 2D 구조의 CA-CFAR를 사용하였다. 제안된 시스템은 다가오는 객체만을 감지할 필요성이 있기에 RD map(Range-Doppler map)에서 Doppler 축의 0인 지점을 기준으로 왼쪽에 있는 데이터만을 알고리즘을 적용시켜 연산량을 감소시켰다. 2D CA-CFAR의 기본적인 구조는 그림 2와 같다.




Fig. 2. Basic structure of 2D CA-CFAR. 그림 2. 2D CA-CFAR의 기본적인 구조

4. DBSCAN

DBSCAN은 다수의 데이터 집합을 밀도를 기반으로 클러스터링하여 나타내는 방식이다. 이는 특정 데이터를 중심으로 반경에 minpts(minimum points) 이상의 데이터가 포함되면 유효한 데이터로 간주하여 그 외에는 잡음으로 처리하는 알고리즘이다. 즉, 높은 밀도의 데이터는 유효한 클러스터로 할당되며 낮은 밀도의 데이터는 잡음으로 할당된다. DBSCAN 알고리즘의 입력 데이터는 CFAR 알고리즘에서 검출된 타겟 데이터이다. 따라서 CFAR 알고리즘에서 검출된 타겟들 중 일정 밀도 이상의 데이터 집합만이 클러스터로 할당된다.

5. Tracking

레이다 센서에서 탐지된 여러 타겟 중에 관측 타겟이 아닌 ghost target을 제거하기 위한 tracking 작업이 필요하다. DBSCAN에 의해 관측 타겟으로 간주되어도, 일정 시간동안 예측범위 안의 데이터가 들어오지 않으면 해당 타겟을 삭제하는 방식으로 동작한다. Tracking은 filter, association, management로 나뉘진다[6]. Filter는 현재 거리 및 속도를 바탕으로 다음 프레임의 거리 및 속도를 예측한다. Association은 filter가 예측한 데이터와 현재 관측된 데이터를 비교하여 가장 인접한 데이터를 트랙에 업데이트한다. Management는 업데이트된 데이터를 기준으로 새로운 트랙을 생성하거나 트랙의 종류를 판별한다. Tracking 알고리즘이 실행되면, 프레임에 한 번씩 나타나는 데이터 집합들은 노이즈로 간주되어 사라지고 프레임에 계속 관찰되는 관측 데이터 집합만이 남게 된다.

6. Spectrogram

스펙트로그램은 본래 소리나 파동을 시각화하여 파악하기 위한 도구로 널리 사용된다. 본 논문에서는 객체 분류를 위한 용도로 스펙트로그램을 활용하며, tracking 결과로 취득한 객체의 위치 정보를 이용한다. 해당 객체의 위치를 기준으로 ROI(Region of Interest)를 설정한 후, ROI 안의 micro-Doppler 성분들을 처리하여 스펙트로그램을 생성한다. 결과적으로 객체의 micro-Doppler 성분에 따라, 분류 가능한 다른 형상의 스펙트로그램이 생성된다.

7. BNN

CNN은 주로 이미지 인식, 패턴 인식 및 컴퓨터 비전과 같은 작업에서 사용되는 딥러닝의 한 종류이다. CNN은

기본적으로 Convolution Layer, Activation Function Layer, Pooling Layer, Fully Connected Layer 등의 여러 계층으로 구성된 신경망이다. 이 계층들을 거쳐 나온 최종 feature map을 기반으로 확률적인 분류가 이루어진다.

BNN은 CNN의 모든 입력과 가중치를 이진화하여 연산한다. 모든 MAC(Multiply-Accumulate) 연산은 XNOR와 popcount로 대체하여 연산량 및 메모리 요구량을 줄일 수 있다. 또한, 활성화 함수를 hard hyperbolic tangent로 사용하면 배치 정규화와 결합하여 단순 비교만으로 연산을 수행할 수 있게 되어 연산량을 더욱 감소시킬 수 있다.

III. 시스템 개요

1. 시스템 구조

본 논문에서 제안된 시스템에서는 ANALOG DEVICE사의 DEMORAD FMCW 레이더 센서를 사용하여 실험 환경에서 데이터를 취득하고, 그 데이터를 신호처리하여 스펙트로그램을 생성한 뒤 FPGA(Field-Programmable Gate Array) 상에서 BNN 연산을 통해 얻은 결과로 객체를 분류한다. 레이더의 주파수 대역은 24GHz이고 bandwidth는 300MHz이다.

시스템 구조는 그림 3과 같다. Raspberry-Pi에서 FMCW 레이더 센서에 커맨드를 보내고 측정된 raw data를 전송받는다[8]. 전송받은 데이터는 256×128 단위로 FFT 연산을 수행하여 RD map을 생성한다. 생성된 RD map에 대해 2D CA-CFAR 알고리즘을 적용하여 타겟에 대한 검출이 진행된다. 적용된 CA-CFAR 알고리즘의 파라미터는 표 1과 같다.




Fig. 3. Structure of the proposed system.
그림 3. 제안된 시스템의 구조

DBSCAN을 통해 타겟과 노이즈에 대한 클러스터링을 한 뒤 FFT 연산 결과의 절대값이 가장 큰 값을 대푯값으로 설정한다. 다음으로 tracking 알고리즘을 거쳐 최종적인 객체에 대한 tracking 정보를 얻어내고, 이를 기반으로 스펙트로그램을 생성한다. 이후 SPI 통신을 통해 스펙트로그램을 FPGA에 전송하고 BNN 연산을 수행한 뒤 결과를 수신받고, 자전거, 자동차, 사람 중 하나의 객체로 분류하여 생성된 스펙트로그램과 함께 화면에 표시된다.

Table 1. Parameters used in CA-CFAR.

표 1. CA-CFAR에 사용된 parameters

Parameters	Value
rcell	10
gcell	5
Pfa	1e-5

2. BNN 분류 성능평가

BNN 설계는 FPGA 상 가속기 설계를 목표로 하였기에 파라미터 수를 고려하여 설계되었다. 자전거 1,166개, 자동차 837개, 사람 1,004개로 총 3,007개의 데이터셋을 사용하였고, 이 중 2,407개는 학습에 사용하였고 검증과 평가에는 300개씩 사용하였다. BNN 성능에 대한 검증 결과는 표 2에 정리하였다. Conv(Convolution Layer)는 입력 데이터의 특징을 추출하는 역할을 하며, 작은 kernel을 사용하여 이미지나 신호의 중요한 패턴을 감지한다. Maxpooling에 의한 데이터 손실을 최소화하기 위해 첫 번째 Conv의 kernel 크기를 5×5로 설정하였고 이후 연산에서는 3×3 커널을 사용하였다. FCL(Fully Connected Layer)는 최종 분류 단계에서 사용되어 입력 데이터를 특정 class에 매핑하는 역할을 수행

Table 2. Accuracy and number of parameters according to BNN layer configuration.

표 2. BNN layer 구성에 따른 정확도 및 parameter 수

# Conv	# FCL	Accuracy (%)	# Parameter
2	1	79.333	89,539
	2	85.000	1,256,899
3	1	86.333	383,427
	2	87.333	1,421,251
4	1	89.000	964,553
	2	90.333	1,225,155
5	1	84.667	1,000,521
	2	79.667	1,261,123

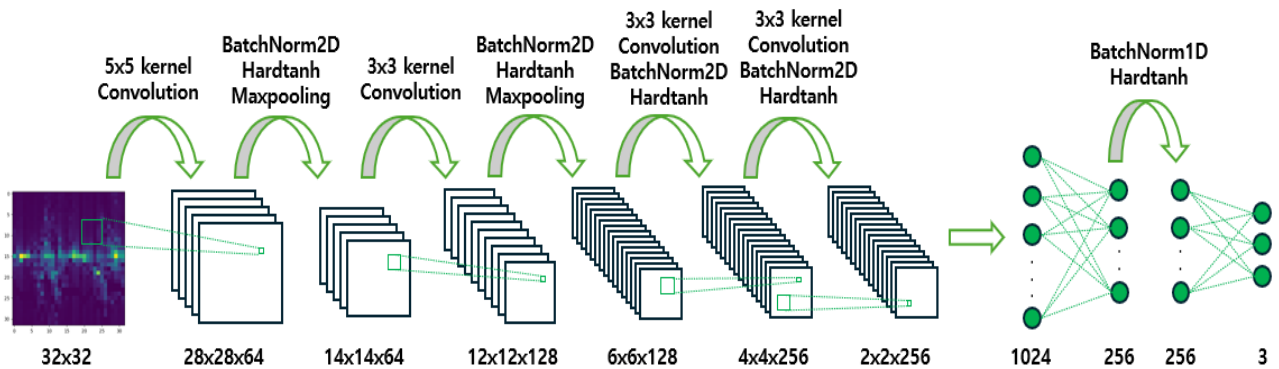


Fig. 4. BNN structure of proposed system.
 그림 4. 제안된 시스템의 BNN 구조

한다. Loss function으로 CrossEntropy를 사용하였고, optimizer로 Adam을 사용하였다. Hyper parameter로는 batch size는 64, learning rate는 0.001, epoch는 500을 사용하였다. 최종적인 BNN 구조는 그림 4에 나타내었다.

IV. 실험

1. 데이터 취득

실험 환경은 센서가 차량의 사이드미러에 부착되어야 한다는 것을 고려하여, 그림 5와 같이 Raspberry-Pi와 연결과 레이더를 지면에서 1m 높이에 배치하였다. 자동차는 30m 지점에서 최대 30km/h의 속도로, 자전거는 30m 지점에서 최대 20km/h의 속도로, 사람은 20m 지점에서 최대 10km/h의 속도로 레이더 센서를 향해 이동하며 데이터 취득을 수행하였다.

0.1초마다 한 프레임의 데이터를 취득하여 총 측정시간 10초동안 100 프레임을 취득했고, 그 중 32 프레임을 이용하여 하나의 스펙트로그램을 생성하였다.




Fig. 5. Experiment environment : (a) Bicycle, (b) Car, (c) Human.
 그림 5. 실험 환경 구성 : (a) 자전거, (b) 자동차, (c) 사람

2. 레이더 신호처리 알고리즘 결과

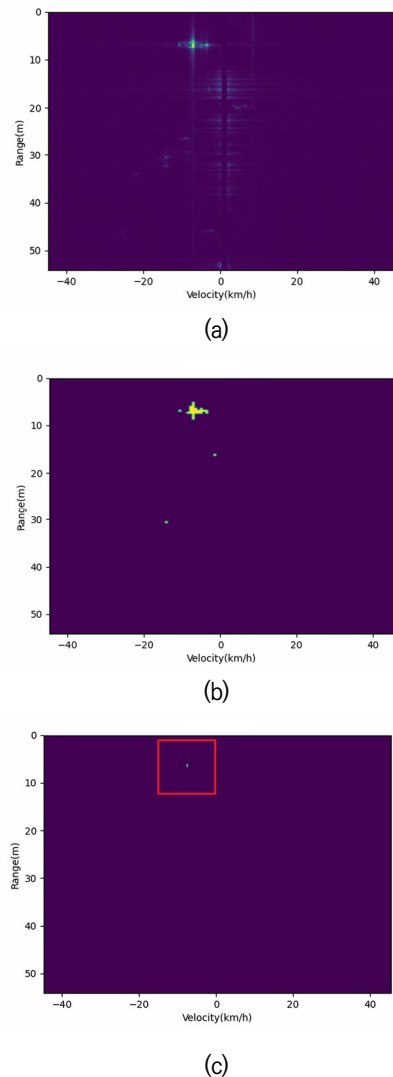


Fig. 6. Radar signal processing result for bicycle : (a) FFT, (b) CFAR, (c) DBSCAN & Tracking.
 그림 6. 자전거에 대한 레이더 신호 처리 결과 : (a) FFT, (b) CFAR, (c) DBSCAN & Tracking

그림 6은 취득한 자전거 데이터를 전처리하여 얻은 결과이다. (a)는 FFT 연산을 한 결과로 자전거 페달을 밟을 때 발생하는 다리의 앞뒤 움직임이 micro-Doppler로 관측된다. (b)는 2D CA-CFAR 알고리즘을 통해 테스트 셀과 주변 셀의 관계를 비교하여 셀을 구분한 결과이다. (c)는 DBSCAN을 적용하여 CFAR 검출량이 적은 데이터는 노이즈로 처리하고, 한 물체로부터 생성된 데이터를 하나의 클러스터로 묶은 뒤 tracking하여 최종적으로 목표의 거리와 속도를 특정지은 결과이다.

3. 하드웨어 설계 및 구현

본 논문에서 제안한 시스템의 하드웨어 구조는 그림 7과 같다. 크게 Raspberry pi와 FPGA와의 데이터 통신을 위한 SPI protocol, 전송받은 데이터에 대해 BNN 연산을 수행하는 BNN IP, 두 모듈을 연결하는 input/output buffer로 구성된다. BNN IP는 Layer block, Memory Controller, State machine, Weight ROM, Threshold ROM으로 구성된다. Layer block의 BNN 연산 구조는 그림 8과 같다. XNOR popcount, Accumulator를 통해 컨볼루션 연산을 수행하고 Comparator를 통해 batch normalization과 activation function인 hard hyperbolic tangent 연산을 수행한다. 그리고 OR 연산을 통해 maxpooling을 수행한다.

제안된 시스템은 Verilog HDL을 이용하여 설계되었고 Intel Altera MAX 10 10M50DAF484C7G FPGA 상에서 검증 및 구현되었다[9]. 1,296KB의 memory, 11,059개의 logic elements, 4,096개의 register가 사용되었으며 20ms의 수행시간으로 실시간 동작이 가능함을 확인하였다.

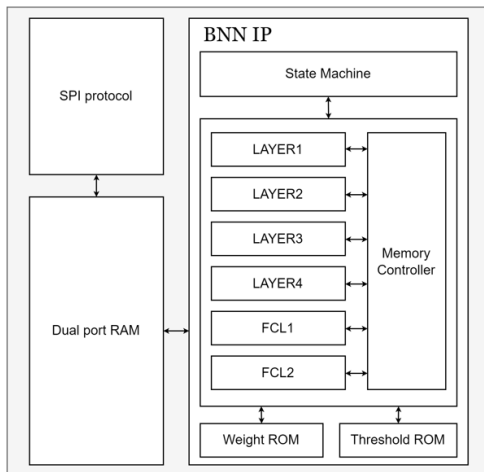


Fig. 7. Hardware structure of proposed system. 그림 7. 제안된 시스템의 하드웨어 구조

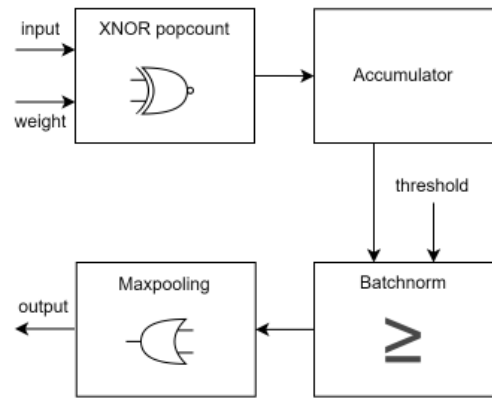


Fig. 8. BNN operation structure of layer block. 그림 8. Layer 블록의 BNN 연산 구조

4. Spectrogram 생성 및 최종 결과

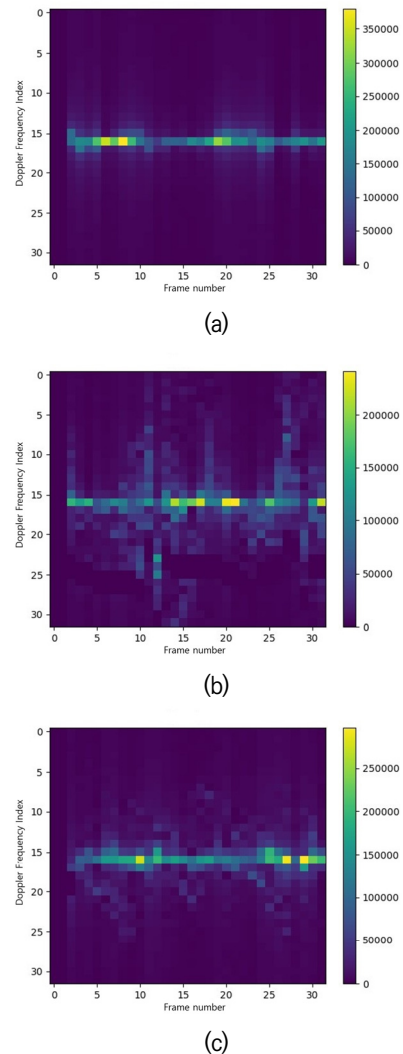


Fig. 9. Spectrogram and prediction results obtained through experiments : (a) Car, (b) Human, (c) Bicycle. 그림 9. 실험을 통해 얻은 스펙트로그램과 예측 결과 : (a) 자동차, (b) 사람, (c) 자전거

신호처리 알고리즘을 거쳐 얻은 객체의 거리를 기준으로 micro-Doppler를 추적하여 스펙트로그램을 생성한다. 그림 9는 생성된 스펙트로그램과 BNN 연산을 통해 분류된 class 결과를 보여준다. 자동차의 경우 바퀴 회전에 따른 미세한 주파수 변화가 있으나 그 움직임이 규칙적이고 차체가 고정되어 운동하기 때문에 micro-Doppler 성분이 거의 관측되지 않는다. 사람의 경우 걸으면서 팔과 다리를 앞뒤로 움직이고 불규칙한 움직임이 발생해 다양한 주파수 변화를 일으키므로 micro-Doppler 성분이 다채롭게 관측된다. 자전거의 경우 페달을 밟는 다리 움직임에 의한 주파수 변화가 발생하나 걷는 사람보다 단순한 주파수 변동을 생성하기 때문에 사람과 자동차의 중간 정도의 micro-Doppler 성분이 관측된다. Micro-Doppler 성분에 따른 스펙트로그램 기반 객체 분류 결과 90.33%의 정확도를 지원 가능함을 확인하였다.

V. 결론

본 논문에서는 FMCW 레이더를 통해 얻은 데이터를 가공하기 위한 FFT, CFAR, DBSCAN, Tracking 등의 신호처리 알고리즘을 구현하였다. 이를 통해 객체를 검출하고 FPGA 상에서 BNN 연산을 통해 객체를 분류하는 시스템을 설계하였다. 실험 환경의 객체로는 자전거, 자동차, 사람을 설정하였고, 실험 및 시뮬레이션으로 총 2,407개의 데이터에 대하여 학습한 성능을 평가하였고 90.33%의 정확도로 객체를 분류하였다. 연산의 가속화와 메모리 사용량을 감소시키기 위해 BNN 가속기를 설계하였고 20ms로 실시간 동작함을 확인하였다.

향후 연구에서는 차량 도어 충돌 사고와 연관된 오토바이, 킥보드 등 다양한 개인형 이동수단(PM)에 대한 데이터셋을 추가로 확보하고, 이를 활용하여 더 많은 객체를 분류할 수 있도록 개선 연구를 진행할 계획이다. 이를 통해 본 시스템은 더욱 다양한 상황과 객체에 대응할 수 있게 되어 차량 탑승객과 주변 보행자의 안전성을 높일 수 있을 것으로 기대된다.

References

[1] Z. -Y. Zhung, K. -C. Chen, Y. -H. Yu and N. Kwok, "Chip-based Anti-collision System for Car Door Opening," *2019 4th International Conference on Intelligent Transportation Engineering (ICITE)*,

pp.322-326, 2019.

DOI: 10.1109/ICITE.2019.8880149

[2] Q. Shen, "Design of Backward Collision Warning and Avoidance System when On-street Parking Using LiDAR," *2021 2nd International Conference on Computing and Data Science (CDS)*, pp.239-242, 2021. DOI: 10.1109/CDS52072.2021.00048

[3] Courbariaux, Matthieu, et al. "Binarized neural networks: Training deep neural networks with weights and activations constrained to+ 1 or-1." *arXiv preprint arXiv:1602.02830*, 2016.

DOI: 10.48550/arXiv.1602.02830

[4] G. -R. Liu, M. -Z. Zhou, L. -L. Wang and H. Wang, "A Radar-Based Door Open Warning Technology for Vehicle Active Safety," *2016 International Conference on Information System and Artificial Intelligence (ISAI)*, pp.479-484, 2016.

DOI: 10.1109/ISAI.2016.0108

[5] Yunsung Sim, Seungjun Song, Seonyoung Jang and Yunho Jung, "Design and Implementation of Human and Object Classification System Using FMCW Radar Sensor," *Journal of IKEEE*, 26.3, pp. 364-372, 2022. DOI: 10.7471/ikeee.2022.26.3.364

[6] E. Hyun and J. -H. Lee, "Multi-target tracking scheme using a track management table for automotive radar systems," *2016 17th International Radar Symposium (IRS)*, pp.1-5, 2016.

DOI : 10.1109/IRS.2016.7497283

[7] Analog Devices, "EVAL-DEMORAD", <https://www.analog.com/en/resources/evaluation-hard-ware-and-software/evaluation-boards-kits/eval-demorad.html#eb-overview>

[8] Raspberry Pi, "raspberrypi-4-model-b", <https://www.raspberrypi.com/products/raspberrypi-4-model-b/>

[9] terasic Technologies, "DE10 - Lite Board", <https://www.terasic.com.tw/cgi-bin/page/archive.pl?Language=English&No=1021>

BIOGRAPHY

Jeong-Woo Han (Member)

2019~present : BS degree in Electronics and Information Engineering, Korea Aerospace University.

Min-Sang Kim (Member)

2019~present : BS degree in Electronics and Information Engineering, Korea Aerospace University.

Dae-Hong Kim (Member)

2019~present : BS degree in Electronics and Information Engineering, Korea Aerospace University.

Yunho Jung (Member)

1998 : BS degree in Department of Electrical and Electronic Engineering, Yonsei University.
2000 : MS degree in Department of Electrical and Electronic Engineering, Yonsei University

2005 : Ph.D degree in Department of Electrical and Electronic Engineering, Yonsei University.
2005~2007 : Senior Engineer, Samsung Electronics.
2007~2008 : Research professor, Institute of Information Engineering, Yonsei University.
2008~present : Professor, School of Electronics and Information Engineering, Korea Aerospace University