

FMCW 레이다 센서 기반 사람과 사물 분류 시스템 설계 및 구현

Design and Implementation of Human and Object Classification System Using FMCW Radar Sensor

심윤성*, 송승준*, 장선영*, 정윤호**★

Yunsung Sim*, Seungjun Song*, Seonyoung Jang*, Yunho Jung**★

Abstract

This paper proposes the design and implementation results for human and object classification systems utilizing frequency modulated continuous wave (FMCW) radar sensor. Such a system requires the process of radar sensor signal processing for multi-target detection and the process of deep learning for the classification of human and object. Since deep learning requires such a great amount of computation and data processing, the lightweight process is utmost essential. Therefore, binary neural network (BNN) structure was adopted, operating convolution neural network (CNN) computation in a binary condition. In addition, for the real-time operation, a hardware accelerator was implemented and verified via FPGA platform. Based on performance evaluation and verified results, it is confirmed that the accuracy for multi-target classification of 90.5%, reduced memory usage by 96.87% compared to CNN and the run time of 5ms are achieved.

요약

본 논문에서는 FMCW(frequency modulated continuous wave) 레이다 센서를 활용한 사람과 사물을 분류하는 시스템 설계 및 구현 결과를 제시한다. 해당 시스템은 다중 객체 탐지를 위한 레이다 센서 신호처리 과정과 객체를 사람 및 사물로 분류하는 딥러닝 과정을 수행한다. 딥러닝의 경우 높은 연산량과 많은 양의 메모리를 요구하기 때문에 경량화가 필수적이다. 따라서 CNN(convolution neural network) 연산을 이진화하여 동작하는 BNN(binary neural network) 구조를 적용하였으며, 실시간 동작을 위해 하드웨어 가속기를 설계하고 FPGA 보드 상에서 구현 및 검증하였다. 성능 평가 및 검증 결과 90.5%의 다중 객체 구분 정확도, CNN 대비 96.87% 감소된 메모리 구현이 가능하며, 총 수행 시간은 5ms로 실시간 동작이 가능함을 확인하였다.

Key words : BNN accelerator, embedded system, FMCW radar, FPGA, multi-target tracking

* School of Electronics and Information Engineering, Korea Aerospace University

** Department of Smart Air Mobility, Korea Aerospace University

★ Corresponding author

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

※ Acknowledgment

This work was supported by Institute of Information & communications Technology Planning & Evaluation(IITP) grant funded by-and-by the Korea government(MSIT) (No. 2020-0-00201, 2022-0-00960) and CAD tools were supported by IDEC.

Manuscript received Aug. 9, 2022; revised Sep. 1, 2022; accepted Sep. 5, 2022.

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.

I. 서론

최근 IoT 기술 발전과 함께 실내 공간에 대한 보안 의식이 증가하고 있다. 개인의 주거 공간뿐만 아니라 특정 공간의 침입자를 감지하는 기술로 카메라, 적외선센서, 레이더 센서를 활용한 시스템이 개발되고 있다[1], [2]. 이러한 실내 공간 객체 인식 기술은 24시간 동작하는 특성상 소형화 및 경량화된 임베디드 시스템이 필수적이다. 카메라 및 적외선센서는 빛, 온도와 같은 외부 환경에 민감하여 객체를 감지하지 못하거나, 대상을 잘못 분류하는 단점이 존재한다. 또한, 카메라의 경우 사람을 통한 화면 관측이 필요하고, 해킹으로 인한 사생활 노출 문제가 발생하는 단점이 있다. 반면, 레이더 센서의 경우 외부 환경에 의한 영향이 적어 매우 어둡거나 밝은 환경에서 객체를 인식할 수 있다. 또한, 움직임에 의한 주파수 변화로 객체를 분류 및 관측할 수 있어 사생활 침해 문제를 해결할 수 있다. 이러한 특성으로 지난 몇 년간 레이더 센서를 활용한 객체 인식 및 분류 기술이 연구되고 있다[3], [4].

레이더 센서의 경우 신호 변조 여부에 따라 CW (continuous wave) 레이더 센서와 FMCW (frequency modulated continuous wave) 레이더 센서로 구분된다[5]. CW 레이더 센서는 도플러 레이더 센서로도 불리며, 신호의 변조 없이 특정 주파수를 지속적으로 방사한다. 이후 객체로부터 반사되는 신호를 통해 물체의 속도를 측정한다. 하지만, 시간 정보는 저장하지 않기 때문에 물체의 거리 정보를 알 수 없다는 단점이 존재한다. FMCW 레이더 센서는 주파수가 변조된 신호를 연속적으로 방사하여 동작하는 방식이다. 해당 특성으로 탐지된 객체의 시간 정보는 거리 정보를 검출하기 위해 사용된다. 이러한 특성은 다른 거리에 위치한 정보를 획득하여 다중 객체를 탐지하는 데 적합하다.

레이더 센서에서 얻은 데이터는 FFT(fast Fourier transform), CFAR(constant false alarm rate) [6]-[9], DBSCAN(density-based spatial clustering of application with noise)[10], [11]을 활용한 신호처리를 통해 객체 검출에 사용된다. 각 객체는 도플러 성분을 축적한 도플러 프로파일로 특징이 구분된다. 따라서, 각 객체의 도플러 정보가 분리되어 검출되지 않는 경우 객체에 대한 정보가 손실된다. 이러한 점을 해결하기 위해 tracking 알고리즘을 적용하여 각 객체의 도플러 정보를 저장한다[12].

레이더 센서를 통한 객체 분류는 SVM(support vector machine), KNN(k -nearest neighbors algorithm)과

같은 기계 학습 방식보다 CNN과 같은 딥러닝 기술이 적용된다. 하지만, CNN의 경우 높은 연산량과 많은 양의 메모리를 요구한다. 이를 해결하기 위해 CNN 연산에 사용되는 feature, weight 등의 정보를 이진화하여 연산하는 BNN을 사용하였다[13]. 해당 방식은 메모리 사용량 및 연산 복잡도를 감소시켜 하드웨어 구현에 적합하다는 특징이 있다.

기존의 객체 탐지 연구는 CW 레이더 센서를 사용하여 단일 객체만을 탐지해, 다양한 객체가 존재하는 실생활의 상황에 적합하지 않다[14], [15]. 따라서, 기존의 선행된 연구를 발전시켜 FMCW 레이더를 활용한 다중 객체 탐지 연구를 진행하였다. 이 과정에서 탐지된 각 객체의 정보를 추적하기 위하여 tracking 알고리즘을 사용하였다. 또한, 사람, 물체, 강아지의 움직임 특성에 따라 구분되는 도플러 특성을 활용하여 객체를 분류하기 위한 BNN을 적용하였다. 레이더 센서 신호를 처리하기 위해 Raspberry-Pi에서 동작하는 소프트웨어를 설계하여 BNN 연산에 필요한 도플러 프로파일을 생성한다. 실시간 동작을 확보하기 위하여 BNN 연산은 FPGA(field programmable gate array)를 사용한 하드웨어 가속기로 구현한다.

본 논문의 구성은 다음과 같다. II장에서는 시스템을 이해하기 위한 배경지식, III장에서는 시스템의 전반적인 구조와 성능 평가에 대해 다룬다. IV장에서는 시스템 설계 및 구현에 관한 내용을 다루며, V장에서는 실험 결과, VI장에서는 결론을 맺는다.

II. Background

1. FMCW 레이더 센서

FMCW 레이더 센서는 송신 주파수를 변조하여 방사하는 방식으로 동작한다. 주파수는 그림 1의 그래프와 같이 f_L 부터 f_H 까지 변조되며, 이 구간을 chirp이라고 한다. 한 chirp에 대한 시간은 T_{chirp} 으로 나타나며, 이러한 chirp이 연속되어 하나의 frame을 구성한다. 이때, 한 frame에 대한 시간은 T_{frame} 으로 나타난다. FMCW 레이더 센서는 frame을 지속적으로 송신 및 수신하여 거리와 속도를 측정한다.

2. FFT 알고리즘

객체의 거리와 속도 정보는 레이더 센서로부터 수신한 데이터를 FFT 연산하여 검출된다. 거리와 속도 정보를 동시에 얻을 수 있는 2D FFT 방식이 존재하지만, 수행 시간을 감소시키기 위해 1D FFT 방식을 두 번 적용하였

다. 우선, 객체의 거리 정보는 chirp 내부의 sample에 대하여 FFT 연산을 수행함으로써 얻어진다. 이후, chirp에 대한 FFT 결과를 frame 단위로 축적한 후 FFT 연산을 진행함으로써 객체의 속도 정보를 검출한다. 두 번의 FFT 연산을 통하여 한 frame 당 하나의 R-D map (range Doppler map)이 구성되며, 각 축은 객체의 거리와 속도 정보를 포함한다. 그림 1은 해당 과정을 그림으로써 표현한 모습이다.

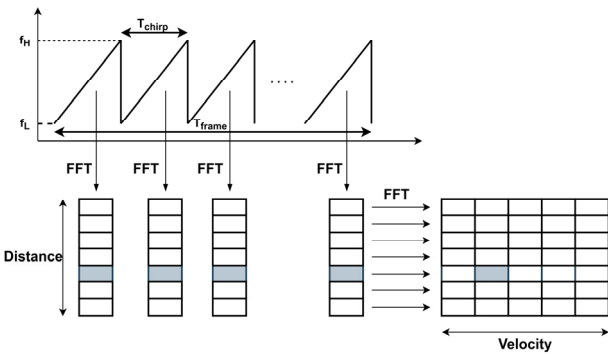


Fig. 1. Process of R-D map configuration using FFT.
 그림 1. FFT를 통한 R-D map 구성 과정

3. CFAR 알고리즘

주파수 성분에 대한 객체 존재 여부는 일반적으로 임계값보다 큰 신호를 탐지하는 방식으로 판별된다. 이때, 임계값이 고정된 경우 객체의 신호 세기가 약하거나 클러터의 신호 세기가 임계값보다 큰 경우 오검출이 발생한다. 따라서, 레이다 센서 시스템은 일정한 오경보 확률을 유지하기 위해 가변 임계값을 계산하는 CFAR(constant false alarm rate) 알고리즘을 사용한다. 그림 2와 같이 CFAR는 target cell을 중심으로 r_{cell} (reference cell)과 g_{cell} (guard cell)로 구성되고, 임계값 계산을 위한 P_{fa} (false probability)를 사용한다.



Fig. 2. Cell configuration of CFAR algorithm.
 그림 2. CFAR 알고리즘의 cell 구성

CFAR는 흔히 CA-CFAR(cell average CFAR)와 OS-CFAR(ordered statistic CFAR)로 구분된다. CA-CFAR는 r_{cell} 값의 평균으로 임계값을 산출하여, 수행 시 연산량이 적으나 객체 간 cell 정보가 중첩되는 경우 탐지 확률이 낮아지는 단점이 있다[6]-[7]. 반면, OS-CFAR의

경우 r_{cell} 값을 정렬한 후 k 번째 cell 기준으로 임계값을 결정하고, 이를 바탕으로 잡음과 실제 객체를 구분하여 target을 검출하는 방식이다[6], [8]. 해당 방식은 정렬을 사용하여 기준을 결정하기 때문에 r_{cell} 내부에 다수의 객체가 존재하여도 각 객체를 검출하는데 뛰어난 성능을 보인다. 하지만, 정렬 과정으로 인하여 연산량이 증가하고, 이에 따라 수행 시간이 길어지는 단점이 있다. 이를 해결하기 위해, 비교 연산을 통해 k 번째 값을 찾는 알고리즘이 제안되었다[16]. 본 논문에서는 해당 알고리즘을 적용하여 OS-CFAR를 구현하였다.

4. DBSCAN 알고리즘

DBSCAN(density-based spatial clustering of application with noise) 알고리즘은 다수의 비선형 데이터 집합을 cluster로 구성하여 하나의 데이터 집합으로 나타내는 방식이다. 이는 특정 범위 이내에 $Minpts$ (minimum point) 이상의 데이터가 존재하면 유효한 데이터로 인지하고, 그 외에는 잡음으로 처리한다. 구현한 시스템에서 각 데이터는 CFAR 알고리즘으로 검출된 target이다. DBSCAN 알고리즘을 통하여 하나의 target에 대한 데이터 집합을 cluster로 구성하는 동시에, 서로 다른 target의 데이터를 다른 cluster로 구성하여 다중 객체를 구분하는 과정을 수행한다.

5. Tracking 알고리즘

레이다 센서로 탐지된 객체를 분류하기 위해 도플러 프로파일이 사용된다. 이때, 다중 객체 환경에서 각 객체의 도플러 정보를 추적하기 위해 움직임에 따른 tracking 알고리즘이 필수적이다. Tracking 알고리즘은 association, management, filter로 나뉜다. Association은 한 frame 이전 상태에서 filter가 예측한 객체의 데이터와 현재 관측된 데이터를 기준으로 가장 인접한 데이터를 track에 업데이트한다. Management는 업데이트된 데이터를 기준으로 새로운 track을 생성하거나 track의 종료를 판별한다. Filter는 track이 유지되는 경우 객체의 현재 거리 및 속도 정보를 바탕으로 다음 frame의 거리 및 속도를 예측한다.

6. BNN

딥러닝 기술인 CNN은 학습된 kernel과 이미지의 convolution 연산을 통해 특징을 추출한다. 이후 FCL (fully connected layer)을 통해 활성화된 특징을 기반으로 확률적 분류가 이루어진다. BNN은 딥러닝 네트워크

크의 일종으로 기존 CNN의 모든 파라미터를 이진화하여 학습 및 추론한다. 따라서, 이는 부동소수점으로 연산하는 곱하기 및 누적 과정을 XNOR과 popcount로 대체하여 연산량을 대폭 감소시킬 수 있다. 또한, 연산에 필요한 파라미터와 연산 결과를 저장하는 메모리 사용량이 감소하여 빠른 연산이 가능하다. 이러한 구조는 경량화 및 소형화가 필수적인 임베디드 시스템에 적합하다.

III. 시스템의 개요

1. 시스템 구조

시스템 개요는 그림 3과 같이 나타난다. Raspberry-Pi는 레이더 센서를 구동하기 위해 UART(universal asynchronous receiver /transmitter) 통신으로 command 신호를 송신하고, 레이더 센서에서 생성된 raw 데이터를 수신한다. 수신한 데이터는 DC removal을 통해 잡음 성분이 제거된다. 레이더 센서 신호처리에 사용되는 FFT와 CFAR의 경우 시간 복잡도가 높은 2D 연산을 거리와 속도로 분리하여 1D 연산으로 수행하였다[9]. Chirp 단위로 64 point FFT를 수행하여 거리에 따른 주파수 값을 검출하고 OS-CFAR를 통해 객체가 있는 거리를 탐지한다. 탐지된 주파수를 기준으로 frame 단위의 64 point FFT를 수행하여 속도 정보를 얻는다. 두 번의 FFT 결과로 생성된 R-D map은 이전 frame의 결과와 subtraction을 진행하여 정적인 신호 성분이 제거된다[17]. 이후 속도 축으로 OS-CFAR를 적용하여 거리, 속도 정보를 포함한 객체를 탐지한다.

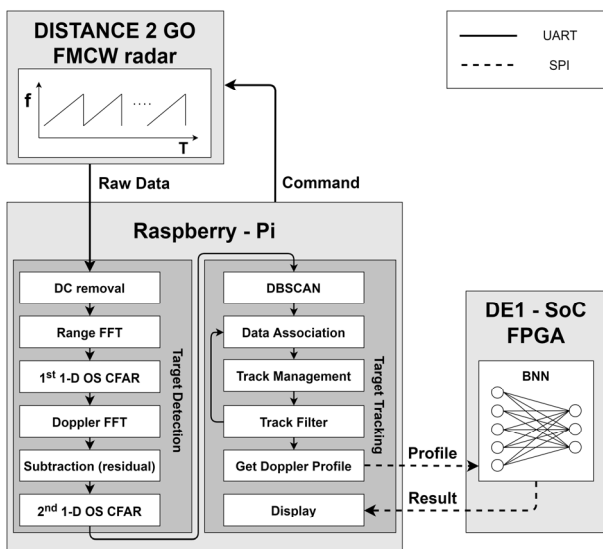


Fig. 3. Data processing flowchart for the proposed system. 그림 3. 제안된 시스템의 데이터 처리 흐름도

탐지된 다중 객체는 사람과 사물로 분리된 후, 각각에 대한 도플러 프로파일이 요구된다. 따라서, 추적과정을 적용하여 사람과 사물에 대한 도플러 프로파일을 생성한다. 추적과정은 먼저, DBSCAN 알고리즘을 통해 cluster를 생성하고, 신호의 세기를 기준으로 대푯값을 선정하여 tracking 알고리즘이 수행된다. 각 객체에서 생성된 도플러 프로파일은 그림 4와 같다. 도플러 프로파일은 SPI(serial peripheral interface) 통신으로 FPGA에 전송된다. BNN 연산을 통해 객체의 class를 구분하고, 결과를 Raspberry-Pi에 전달한다.

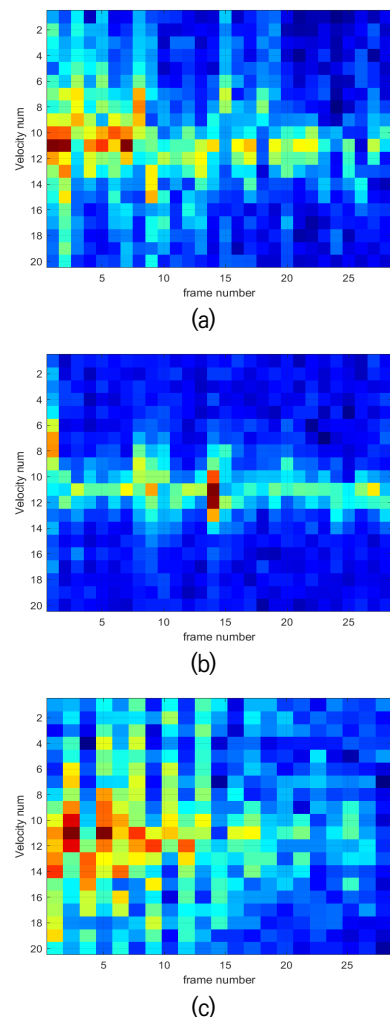


Fig. 4. Doppler profile for (a) human, (b) object, (c) dog. 그림 4. (a) 사람, (b) 물체, (c) 강아지에 대한 도플러 프로파일

2. BNN 성능 평가

BNN은 FPGA 상에서 하드웨어 가속기로 구현되기 때문에 네트워크의 크기 및 정확도, 메모리 사용량을 고려하여 설계되었다. 해당 network는 사람, 물체, 강아지 총 3개의 class를 구분하며, 사람 471개, 물체 495개,

강아지 488개로 총 1,454개의 데이터를 사용하였고, 1,154개는 학습에 나머지 300개는 평가에 사용하였다. 학습 과정에서 cross entropy loss function과 adam optimizer을 사용하였으며, learning rate는 0.0005, epoch는 300, batch size는 8을 적용하였다.

표 1은 BNN의 convolution layer와 FCL 구성에 따른 정확도와 메모리 사용량을 측정된 결과이다. Convolution layer 3개, FCL 2개의 조합이 가장 높은 정확도로 확인되었다. 표 2는 메모리 사용량을 감소시키기 위하여 각 단계의 depth를 변경하며 BNN과 CNN의 정확도 및 메모리 사용량을 비교한 결과이다. 본 연구에서는 90.5%의 정확도와 약 198KB 메모리를 사용하는 BNN을 구현하였으며, 해당 network는 동일 구성의 CNN 대비 3.13%의 메모리를 사용한다.

최종 network 구조는 그림 5와 같다. 입력 이미지는 20×28의 도플러 프로파일이다. 첫 번째 convolution layer는 움직임에 의한 도플러 특성을 고려하여 5×5 크기의 kernel을 사용하였고, 이후 convolution layer의 kernel은 3×3 크기를 사용하였다. 각 layer의 activation function은 hard hyperbolic tangent를 사용하였으며, max pooling과 batch normalization을 적용하였다.

Table 1. Accuracy and memory usage according to the BNN layer configuration.

표 1. BNN layer 구성에 따른 정확도 및 메모리 사용량

# Conv	# FCL	Accuracy (%)	Memory (KB)
2	1	80.3	23.9
	2	88.8	791.6
3	1	88.0	113.3
	2	92.3	420.8
4	1	70.0	385.5
	2	83.3	2226.8
5	1	68.3	923.7
	2	79.3	1537.9

Table 2. Accuracy and memory usage according to the BNN depth configuration.

표 2. BNN depth 구성에 따른 정확도 및 메모리 사용량

	CNN					
	1024			512		
FCL nodes	1024			512		
Conv depth	128	256	512	128	256	512
Accuracy (%)	98.3	99	99	99	99	99
Memory (KB)	2777	7902	25229	1985	6323	22077
	BNN					
	1024			512		
FCL nodes	1024			512		
Conv depth	128	256	512	128	256	512
Accuracy (%)	85.3	91.1	92.3	79	90.5	92
Memory (KB)	86.8	246.9	788.4	62	197.6	689

IV. 시스템의 구조 설계 및 구현 결과




Fig. 6. Verification environment of the proposed human and object classification system.

그림 6. 제안된 사람 사물 분류 시스템의 검증 환경

제안된 시스템의 동작을 검증하기 위해 Infineon Distance2GO 제품을 사용하였다[18]. 또한, Raspberry-Pi 4 Model B 제품에서 소프트웨어를 동작해 레이더 센서에서 얻은 신호를 처리하였다[19]. 검출한 도플러 프로파일을 분류하기 위한 BNN 연산은 Altera Cyclone V

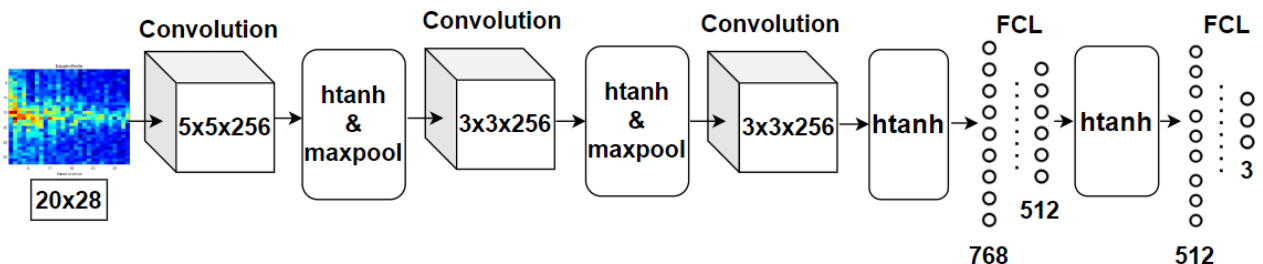


Fig. 5. BNN structure of the proposed system.

그림 5. 제안된 시스템의 BNN 구조

5CSEMA5F31C6N FPGA 상에서 하드웨어 가속기로 구현되고[20], 결과를 Raspberry-Pi와 연결된 모니터에 display 함으로써 확인하였다. 그림 6은 해당 시스템의 연결을 보여준다.

1. 소프트웨어 설계 및 구현

소프트웨어는 레이더 센서 통신 모듈, 신호 전처리 모듈, 출력 모듈로 구성된다. 레이더 센서 통신 모듈은 레이더 센서를 사용하기 위한 초기 parameter를 전송하는 부분과 레이더 센서에서 얻어진 데이터를 수신하는 부분으로 나누어진다. 초기 parameter는 레이더 센서 동작 주파수 24GHz 및 대역폭 200MHz, 32 sample/chirp, 48 chirp/frame으로 구성된다. 신호 전처리 모듈은 FFT, CFAR, DBSCAN, tracking 알고리즘을 수행한다. 객체와 잡음을 분류하기 위한 CFAR parameter는 표 3과 같다. 출력 모듈은 R-D map과 class 분류 결과를 모니터에 출력한다.

Table 3. Parameter used in OS-CFAR operation.

표 3. OS-CFAR 동작에 사용된 parameter

Parameters	Value
$r_{cell,r}$ (range)	10
$g_{cell,r}$ (range)	0
$r_{cell,v}$ (velocity)	10
$g_{cell,v}$ (velocity)	2
P_{fa}	10^{-5}
k_r (range)	8
k_v (velocity)	10

2. 하드웨어 설계 및 구현

설계한 하드웨어 구성은 그림 7과 같이 통신을 위한 SPI block, class를 분류하는 BNN block으로 구성된다. 두 block은 dual port RAM으로 데이터를 공유한다. BNN block에서는 연산을 수행하는 BNN unit, 연산 단계를 조절하는 state machine, memory controller, 연산에 필요한 weight 및 임계값을 저장하는 ROM으로 구성된다. BNN unit은 XNOR, popcount 연산기를 통해 곱셈 연산과 누적 연산을 수행한다. 또한, Batch normalization과 activation function인 hard hyperbolic tangent는 단순 비교기로 구현되었다. 그림 8은 해당 과정을 도식화한 모습이다.

해당 BNN 가속기는 Verilog HDL로 작성하였으며, FPGA 상에서 구현과 검증이 진행되었고, 5ms의 실행

시간을 확인하였다. 표 4와 같이 하드웨어 시스템 구현에 3,029개의 logic과 1,689 Kbits의 memory, 1,202개의 register가 사용되었다.

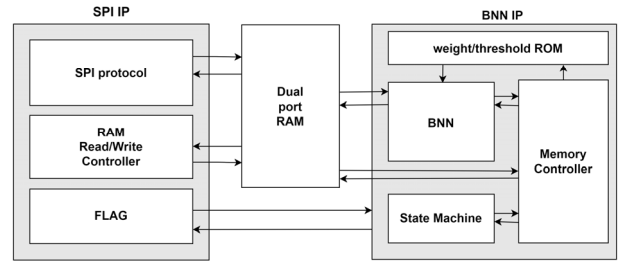


Fig. 7. Structure of the proposed hardware accelerator. 그림 7. 제안된 하드웨어 가속기 구조

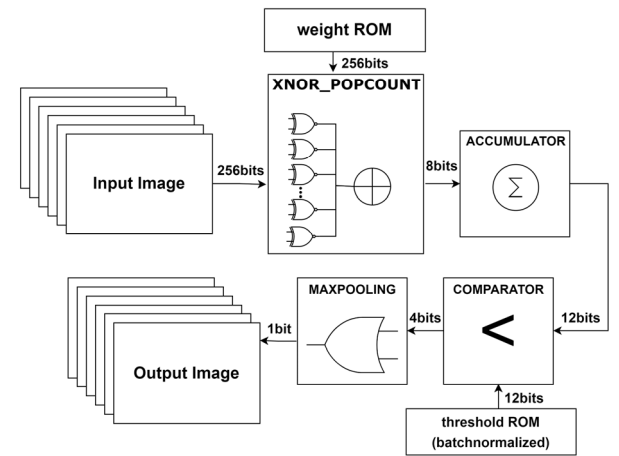


Fig. 8. Unit structure of performing BNN operations. 그림 8. BNN 연산을 수행하는 unit 구조

Table 4. Implementation result of the proposed system.

표 4. 제안된 시스템의 구현 결과

Parameters	Value
Logic utilization	3,029
Total memory bits	1,688,876
Total registers	1,202

V. 실험 결과

실험 환경은 그림 9와 같이 레이더 센서를 지면으로부터 80cm 높이에 위치시켰으며, 한 frame의 시간은 0.1초로 동작하였다. 사람은 12m 지점에서 약 1.8m/s의 속도로 레이더 센서와 가까워지는 방향으로 이동했으며, 물체는 3m 지점에서 약 1.2m/s의 속도로 레이더 센서와 멀어지는 방향으로 이동하였다. 측정 시간은 5초이며, 9m를 이동하는 사람과 6m를 이동하는 물체에 대한 움직임을 50 frame 동안 추적한다. 얻어진 데이터에 대하

여 전처리과정을 거쳐 도플러 프로파일을 생성한 결과는 그림 10과 같다.

그림 11은 전처리과정을 거쳐 얻어진 객체의 도플러 프로파일을 BNN을 통해 사람과 사물로 분류하고 색으로 class를 표현한 사진이다. 각 객체의 값을 추적하여 다중 객체 환경에서 사람과 물체를 분리하여 인식 가능함을 확인할 수 있다.



Fig. 9. Experiment environment.

그림 9. 실험 환경 구성




Fig. 10. Doppler profile observed through experiment
(a) human, (b) object.

그림 10. 실험을 통해 관측한 도플러 프로파일 (a) 사람, (b) 물체

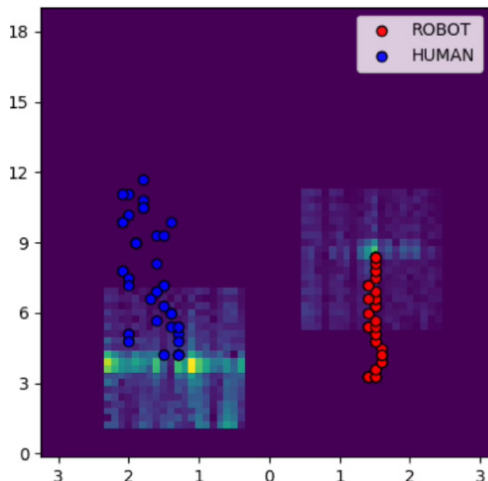


Fig. 11. R-D map of the last frame.

그림 11. 마지막 frame에서의 R-D map

VI. 결론

본 논문에서는 BNN을 활용한 다중 객체 검출 및 분류 시스템을 제안하였다. 3실내 환경의 객체로 사람, 물체, 강아지의 프로파일을 정의하였고, 각 객체를 인식하는 CFAR, tracking 과정을 포함한 데이터 전처리 알고리즘을 구현하였다. 해당 시스템은 연산의 가속화를 위해 BNN 연산을 하드웨어 가속기로 설계하였고, 연산 시간은 5ms로 실시간 동작이 가능함을 확인하였다. 실험 및 시뮬레이션으로 총 1,454개의 데이터에 대하여 학습한 성능을 평가한 결과 물체 88.2%, 사람 91.2% 강아지 92.1%의 분류 정확도를 가지면서 CNN 대비 메모리 사용량이 96.87% 감소함을 확인하였다.

References

- [1] A. Jalil and M. Matalangi, "Object motion detection in home security system using the binary-image comparison method based on robot operating system 2 and Raspberry Pi," *Ilk. J. Ilm.*, vol.13, no.1, pp.1-8, 2021.
DOI: 10.33096/ilkom.v13i1.686.1-8
- [2] I. G. M. N. Desnanjaya and I. N. A. Arsana, "Home security monitoring system with IoT-based Raspberry Pi," *Indones. J. Electr. Eng. Comput. Sci.*, vol.22, no.3, pp.1295-1302, 2021.
DOI: 10.11591/ijeecs.v22.i3
- [3] G. Wang, J.-M. Muñoz-Ferreras, C. Gu, C. Li, and R. Gómez-García, "Application of linear-frequency-modulated continuous-wave (LFMCW) radars for tracking of vital signs," *IEEE Trans. Microw. Theory Techn.*, vol.62, no.6, pp.1387-1399, 2014. DOI: 10.1109/TMTT.2014.2320464
- [4] H. Lee, B.-H. Kim, and J.-G. Yook, "Path loss compensation method for multiple target vital sign detection with 24-GHz FMCW radar," in *Proc. IEEE Asia-Pacific Conf. Antennas Propag. (APCAP)*, pp.100-101, 2018.
DOI: 10.1109/APCAP.2018.8538182
- [5] H. Rohling and M. Kronauge, "New radar waveform based on a chirp sequence," in *Proc. Int. Radar Conf.*, pp.1-4, 2014.
DOI: 10.1109/RADAR.2014.7060246

- [6] M. Kronauge, H. Rohling, "Fast Two-Dimensional CFAR Procedure," *IEEE Trans. Aerosp. Electron. Syst.*, vol.49, no.3, pp.1817-1823, 2013.
DOI: 10.1109/TAES.2013.6558022
- [7] H. Rohling, "Radar CFAR thresholding in clutter and multiple target situations," *IEEE Trans. Aerosp. Electron. Syst.*, vol.AES-19, no.4, pp.608-621, 1983.
DOI: 10.1109/TAES.1983.309350
- [8] H. Rohling, "Ordered statistic cfar technique-an overview," in *Proc. 12th Int. Radar Symp. (IRS)*, pp.631-638, 2011.
- [9] Q. Zheng et al., "A target detection scheme with decreased complexity and enhanced performance for range-Doppler FMCW radar," *IEEE Trans. Instrum. Meas.*, vol.70, pp.1-13, 2021.
DOI: 10.1109/TIM.2020.3027407
- [10] Martin Ester, Hans-Peter Kriegel, Jörg Sander, and Xiaowei Xu, "A density-based algorithm for discovering clusters in large spatial databases with noise," In *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining (KDD'96)*, pp.226-231, 1996.
- [11] Nagesh Singh Chauhan, "DBSCAN Clustering Algorithm in Machine Learning," <https://www.kdnuggets.com/2020/04/dbscan-clustering-algorithm-machine-learning.html>
- [12] E. Hyun and J.-H. Lee, "Multi-target tracking scheme using a track management table for automotive radar systems," in *Proc. 17th Int. Radar Symp. (IRS)*, pp.1-5, 2016.
DOI: 10.1109/IRS.2016.7497283
- [13] Hieu Vo Quang, L. W. Kim, C. S. Hong, "A Deep Learning Accelerator for a Typical Binary Neural Network Layer," *KCC*, pp.597-599, 2021.
- [14] D. H. Jang, H. Kim, Y. H. Jung, "Design and implementation of human-detecting radar system for indoor security applications," *The Institute of Korean Electrical and Electronics Engineers*, vol.24, no.3, pp.783-790, 2020.
DOI: 10.7471/ikeee.2020.24.3.783
- [15] Jeonghee Nam, Chaeyoung Kang, Jeongyeon Kook, Yunho Jung, "Design and Implementation of CW Radar-based Human Activity Recognition

System," *Korea Citation Index (kci)*, vol.25, no.5, pp.415-425, 2021.

[16] Young-Joo Kong, Seon-Keol Woo, Sungho Park, Seung-Yong Shin, Youn Hui Jang, Eunjung Yang, "OS CFAR Computation Time Reduction Technique to Apply Radar System in Real Time," *The Journal of Korean Institute of Electromagnetic Engineering and Science*, vol.29 no.10, pp.791-798, 2018. DOI: 10.5515/KJKIEES.2018.29.10.791

[17] Md Alamgir Hossain, Md Imtiaz Hossain, Md Delowar Hossain, Ji Hoo Chun, Eui-Nam Huh, "Performance Assessment of Background Subtraction Algorithm," *Korea Software Congress*, pp.1049-1051, 2019.

[18] Infineon Technologies, "DEMO DISTANCE2GO" <https://www.infineon.com/cms/en/product/evaluation-boards/demo-distance2go/>

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

[20] terasic Technologies, "DE1 - SoC Board," <https://www.terasic.com.tw/cgi-bin/page/archive.pl?Language=English&No=836>

BIOGRAPHY

Seon-Young Jang (Member)



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

Seung-Jun Song (Member)



2017~present : BS degree in Electronics and Information Engineering, Korea Aerospace University.

Yun-Seong Sim (Member)

2017~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