

보안 감시용 레이다 시스템을 위한 면적-효율적인 특징점 추출기 설계

Design of Area-efficient Feature Extractor for Security Surveillance Radar Systems

최 영 응*, 임 재 형*, 김 건 우*, 정 윤 호*

Yeongung Choi*, Jaehyung Lim*, Geonwoo Kim*, Yunho Jung*

Abstract

In this paper, an area-efficient feature extractor was proposed for security surveillance radar systems and FPGA-based implementation results were presented. In order to reduce the memory requirements, features extracted from Doppler profile for FFT window-size are used, while those extracted from total spectrogram for frame-size are excluded. The proposed feature extractor was design using Verilog-HDL and implemented with Xilinx Zynq-7000 FPGA device. Implementation results show that the proposed design can reduce the logic slice and memory requirements by 58.3% and 98.3%, respectively, compared with the existing research. In addition, security surveillance radar system with the proposed feature extractor was implemented and experiments to classify car, bicycle, human and kickboard were performed. It is confirmed from these experiments that the accuracy of classification is 93.4%.

요 약

본 논문에서는 보안 감시용 레이다 시스템을 위한 저복잡도 특징점 추출기를 제안하고, 이의 FPGA 기반 설계 결과를 제시하였다. 특징점 추출기의 메모리 요구량을 최소화하기 위해 레이다 스펙트로그램 전체에 대한 통계처리를 요구하는 프레임 단위의 특징점을 배제하고, 단위 도플러 프로파일에서 추출 가능한 특징점을 적용하였다. 제안된 특징점 추출기는 Verilog-HDL을 이용하여 RTL 설계 후, Xilinx Zynq-7000 FPGA를 활용하여 구현되었으며, 기존 연구대비 58.3%의 slice 및 98.3%의 메모리 요구량을 감소 가능함을 확인하였다. 또한, 제안된 특징점 추출기가 통합된 레이다 기반 보안 감시 시스템을 통해 차, 자전거, 보행자 및 전동 킥보드에 대한 분류 실험이 수행되었고, 성능 분석 결과 93.4%의 정확도 성능을 확인하였다.

Key words : Feature extraction, micro-doppler, radar, radar target classification, spectrogram

* 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 Institute of Information & communications Technology Planning & Evaluation (IITP) grant funded by the Korea government (MSIT) (No. 2019-0-00056) and CAD tools were supported by IDEC. Manuscript received Mar. 6, 2020; revised Mar. 20, 2020; accepted Mar. 24, 2020.

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.

1. 서론

현대 사회에서는 다양한 센서 기반의 보안 및 감시 시스템이 운용되고 있다. 자동문 시스템 등에 사용되는 적외선의 변화량을 감지하는 PIR(pyroelectric infrared) 센서, 차량 출입 통제 시스템에 사용되는 루프코일 센서와 차량 후방감지 시스템 등에 사용되는 초음파 센서가 대표적이다. 하지만, 이러한 센서들은 온도와 바람과 같은 외부환경에 의한 오작동률이 높고, 탐지거리가 짧은 단점을 가진다. 특히, 루프 코일 센서의 경우 사용하기 위해 직접 도로에 매설해야하기 때문에 설치 및 유지 보수 시

차로가 통제되며, 도로 파손에 의한 훼손 우려도 존재한다는 단점이 있다[1]. 이와 다르게, 전자기파를 사용하여 표적을 탐지하는 레이더 센서는 주변 환경에 영향을 적게 받기 때문에 오작동률이 낮고, 밝기와 상관없이 야간에도 사용이 가능하며, 탐지 거리가 길고 표적의 미세한 변화까지도 측정이 가능하다는 장점이 있으며, 장애물을 투과하여 표적을 탐지할 수도 있다[2].

레이더를 이용한 감시 시스템에서는 타겟을 검출하는 것뿐만 아니라 사람의 다양한 동작이나, 사람과 동물 또는 다른 물체들을 분류하는 타겟 인식에 대한 연구도 활발히 진행되고 있다[3-6]. 레이더를 이용해 타겟을 분류하기 위해서 우선적으로 수행해야 할 신호처리는 수집한 데이터를 이용해 타겟의 스펙트로그램(spectrogram)을 얻을 수 있는 단시간 푸리에 변환(short-time Fourier transform, STFT)이다[7]. 단시간 푸리에 변환을 통해 얻어진 스펙트로그램은 타겟마다 서로 다른 특징을 띄고 있어, 이를 이용하여 서로 다른 타겟을 분류해 낼 수 있다.

타겟을 분류함에 있어서 스펙트로그램을 후처리 과정 없이 타겟 분류를 진행하는 것은 분류 알고리즘의 복잡도와 메모리 요구량이 높아지는 현상을 초래한다. 그러므로, 스펙트로그램에서 다양한 매개변수만을 추출하여 분류를 진행하는 것은 분류 알고리즘의 복잡도와 메모리 사용량을 줄일 수 있기 때문에 필수적이다[3]. 이와 같이 매개변수를 추출하는 과정을 특징점 추출(feature extraction)이라고 하며, 특징점 추출 기법에 따라 시스템의 복잡도와 성능이 결정된다.

레이더로 수집한 데이터에서 특징점을 추출하여 표적 분류를 진행한 연구들로는 사람, 동물 그리고 man-made object를 77%의 성능으로 분류한 연구[4]와 사람, 개, 자전거 그리고 차를 85.3%의 성능으로 분류한 연구[5] 등이 있다. 하지만 이러한 연구들에서 제시된 특징점 추출 기법들 중 일부는 연산 복잡도가 높아 하드웨어 구현 측면에서 많은 연산기가 요구되며, 메모리 요구량도 높다는 단점이 있어 저복잡도 시스템을 설계함에 있어 한계가 존재한다. 예를 들어, 팔과 다리의 동작에 대한 주파수를 연산하기 위해서는 연산 복잡도가 높은 푸리에 변환 관련 연산이 필수적으로 요구되고, target stride를 연산하기 위해서는 나눗셈 연산기가 요구된다[5]. 또한, time-frequency spectrogram의 분산

(variance)을 연산하기 위해서는 스펙트로그램을 모두 메모리에 저장한 뒤 특징점을 추출해야하기 때문에 메모리 요구량이 매우 커지는 문제가 있다[6].

이에, 본 논문에서는 보안 및 감시 응용을 위해 분류 성능을 유지하는 선에서 최소한의 메모리와 연산기를 사용하는 특징점 추출 기법과 특징점 추출기의 하드웨어 구조를 제안한다. 또한, 실험을 통해 얻은 차, 사람, 자전거와 전동 키포드 데이터의 분류를 위하여 높은 분류성능을 가지는 특징점을 추출하고, 이를 낮은 복잡도의 restricted coulomb energy(RCE) 신경망 기법을 통하여 분류 결과를 제시한다[8-10].

본 논문의 구성은 다음과 같다. II장에서는 레이더 기반 타겟 인식 시스템 개요로 레이더 신호 처리, 레이더 신호 처리, 특징점 추출 그리고 분류 알고리즘에 대해 설명하며, III장에서는 본 논문에서 제안하는 특징점 추출 기법에 대해서 설명한다. 또한, IV장에서는 특징점 추출기의 하드웨어 구조에 대해 기술한 뒤, V장에서는 FPGA(field programmable gate array) 기반 하드웨어 구현 결과와 실험 결과 및 분류 성능에 대해 기술한다. 마지막으로 VI장에서 본 논문의 결론을 맺는다.

II. 레이더 기반 타겟 인식 시스템 개요

1. 레이더 신호 처리

다양한 레이더 종류 중 도플러 레이더는 도플러 효과를 이용하여 움직이는 타겟의 속도를 측정한다. 레이더의 정면을 향해서 타겟이 다가오면 수신 받은 신호의 주파수는 송신 신호보다 높은 주파수로 변하게 되며, 이를 도플러 효과라고 한다. 식(1)과 같이 수신 받은 신호의 주파수 $f_{received}$ 와 송신 신호의 주파수 $f_{transmit}$ 의 차이로 계산되는 결과를 도플러 주파수 $f_{doppler}$ 라고 한다.

$$f_{doppler} = f_{received} - f_{transmit} \quad (1)$$

도플러 주파수를 이용해 타겟이 레이더를 향해 방사방향으로 움직일 때 타겟의 시선속도(radial velocity) v 를 식(2)와 같이 계산할 수 있으며, 여기서 c 는 신호의 전파속도이다.

$$v \approx \frac{c}{2f_{transmit}} f_{doppler} \quad (2)$$

레이다 신호를 해석하기 위해서는 수신된 레이더 신호에 윈도우 함수를 적용하여 단시간 신호(short-time signal)로 분할하는 과정이 요구된다. 따라서, STFT를 이용하면 분할된 단시간 신호에 대해서 푸리에 변환을 주기적으로 실행해 타겟의 시간변화에 따른 도플러 주파수의 변화를 분석할 수 있다. STFT는 식(3)으로 표현할 수 있으며, w 는 윈도우의 함수이고, τ 는 윈도우 함수의 지연시간이다.

$$X(\tau, f) = \int_{-\infty}^{+\infty} x(t) \cdot w(t - \tau) \cdot \exp(-j2\pi ft) dt \quad (3)$$

스펙트로그램은 STFT의 결과인 함수 X 를 절대값으로 표현한 함수이다.

2. 특징점 추출

분류 알고리즘의 복잡도를 낮추기 위해서는 입력 데이터의 차원을 낮추는 과정이 필요하다. 스펙트로그램에서 특징점을 추출하여 데이터의 차원을 낮춘다면 분류 알고리즘의 복잡도를 낮출 수 있으며, 메모리 요구량도 낮출 수 있다. 또한, 특징점 추출 기법에 따라 시스템의 복잡도 및 성능이 결정되기 때문에, 적절한 특징점 추출 기법을 선택하는 것은 중요하다.

특징점은 몸통 주파수 (torso frequency)와 몸통

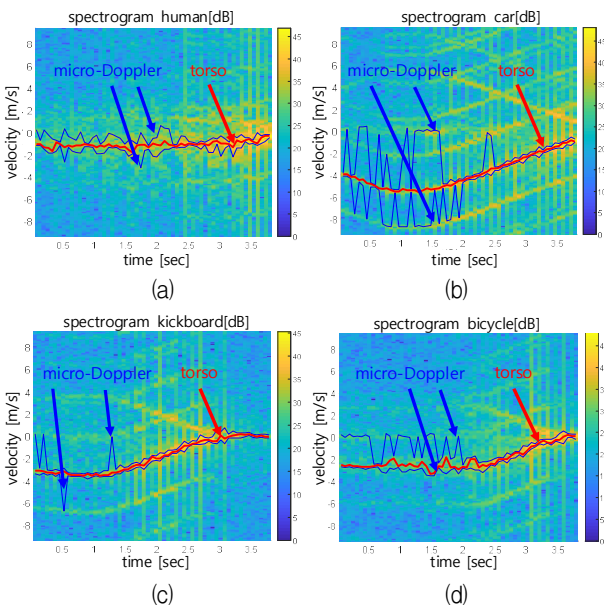


Fig. 1. Spectrogram, (a): a human. (b): a car. (c): a kickboard. (d): a Bicycle.
그림 1. 스펙트로그램, (a): 사람. (b): 차. (c): 전동 킥보드. (d) 자전거

주파수 주변으로 측정되는 미세 도플러 주파수 (micro-Doppler frequency)를 기반으로 추출된다. 타겟의 몸통 속도는 몸통 주파수로 표현되며, 몸통 주변의 팔과 다리 같은 부분의 속도는 미세 도플러로 표현된다. 그림 1에서 보여지듯이, 차, 자전거, 사람과 전동 킥보드 각각은 서로 다른 몸통 주파수와 미세 도플러 주파수로 표현되는 것을 확인할 수 있다.

3. 분류 알고리즘

레이다 센서에서 추출된 특징점으로부터 객체 분류를 수행하기 위해서는 기계학습 기술이 필수적으로 요구되며, 본 논문에서는 RCE 신경망 기법을 통해 분류를 진행한다. RCE 신경망의 구조는 그림 2와 같이 입력층, 은닉층, 출력층 총 3개의 층으로 나뉜다. 입력층은 입력된 특징 데이터로 구성되며, 은닉층은 결정 경계를 형성하는 중심점과 반경을 갖고 있는 뉴런들로 구성 되어있다. 각 뉴런은 구 모양의 활성화 영역을 형성하고 있다. 은닉층의 뉴런은 입력된 특징 값과 뉴런의 중심점 사이의 거리를 구하여 활성화 영역을 기준으로 학습 및 분류를 진행한다. 출력층은 입력 받은 특징점과 가장 유사한 타겟을 출력한다[9-10].




Fig. 2. Structure of an RCE neural network.
그림 2. RCE 신경망 구조

III. 제안하는 특징점 추출 기법

본 논문에서는 최소한의 메모리와 연산기로 구현 가능한 효율적인 특징점 추출 기법을 제안한다. 이를 위해 연산이 복잡한 기존의 기법 대비 연산기 개수를 줄여 연산 복잡도를 낮추었으며, 스펙트로그램 전체에 대한 프레임 단위의 통계처리를 요구

하는 특징점 추출 기법 대비 FFT(fast Fourier transform) 윈도우 단위의 스펙트로그램에 대해서 통계처리를 할 수 있는 기법을 제시함으로써 메모리 요구량을 최소화하였다. 특징점 추출 기법은 4가지를 제안한다. Torso frequency는 타겟 몸통 주파수를 나타내며, Torso bandwidth는 타겟 몸통 주파수의 변화폭을 나타낸다. Bandwidth는 타겟 몸통주파수와 미세 도플러 주파수를 포함한 변화폭을 나타낸다. 앞서 언급된 3가지 특징점은 스펙트로그램에 그림 3과 같이 표현된다. 마지막 특징점 추출 기법 Line variance는 도플러 주파수의 분산을 나타낸다.

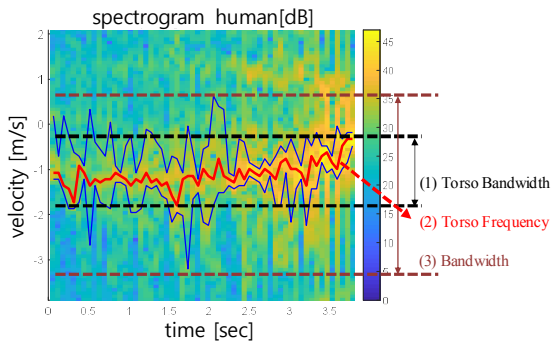


Fig. 3. Proposed features. Feature(1): Torso Bandwidth. feature(2): Torso Frequency. feature(3): Bandwidth.
 그림 3. 제안된 특징점. 특징(1): Torso Bandwidth. 특징(2): Torso Frequency. 특징(3) Bandwidth

1. Torso Frequency

차와 전동 킥보드는 엔진 동력을 이용한 바퀴의 회전운동으로 이동하기 때문에 사람과 자전거에

비해 빠른 속도를 낼 수 있다. 자전거는 사람의 적은 힘으로 큰 힘을 낼 수 있는 구동계와 바퀴의 관성 운동으로 이동하기 때문에 사람보다 빠른 속도를 낼 수 있다. 즉, 차가 가장 빠르며 사람의 속도가 가장 느리다고 볼 수 있다. 따라서, 타겟은 속도가 빠를수록 절대 값이 큰 도플러 주파수를 가지므로, 스펙트로그램에서 매시간 진폭이 가장 큰 도플러 주파수가 타겟의 큰 비중을 차지하는 몸통의 도플러 주파수(torso frequency)이다. 이는 식(4)와 같이 표현 가능하며, S는 스펙트로그램의 함수이다.

$$f^*(\tau) = \max_f \{S(\tau, f)\} \tag{4}$$

제안된 torso frequency를 특징점으로 사용하기 위해서 아래의 식(5)와 같이 N_T 초 동안 측정된 매 단위 시간마다의 몸통 주파수의 평균값을 구하였으며, N_T 는 데이터 측정 시간, f^* 는 도플러 주파수 축의 좌표 값이다.

$$Feature(1) = \frac{1}{N_T} \sum_{\tau=1}^{N_T} f^*(\tau) \tag{5}$$

2. Torso Bandwidth

타겟이 레이더 정면을 향해 접근하다가 레이더에 근접하게 되면 타겟은 정지한 상태로 존재할 것이다. 이러한 정지하기 위한 운동 과정에서 타겟 속도의 감소가 발생한다. 시작 속도가 비교적 빠른 차의 경우 속도의 변화 폭이 크고, 시작 속도가 비교적 느린 사람의 경우에는 속도의 변화 폭이 작

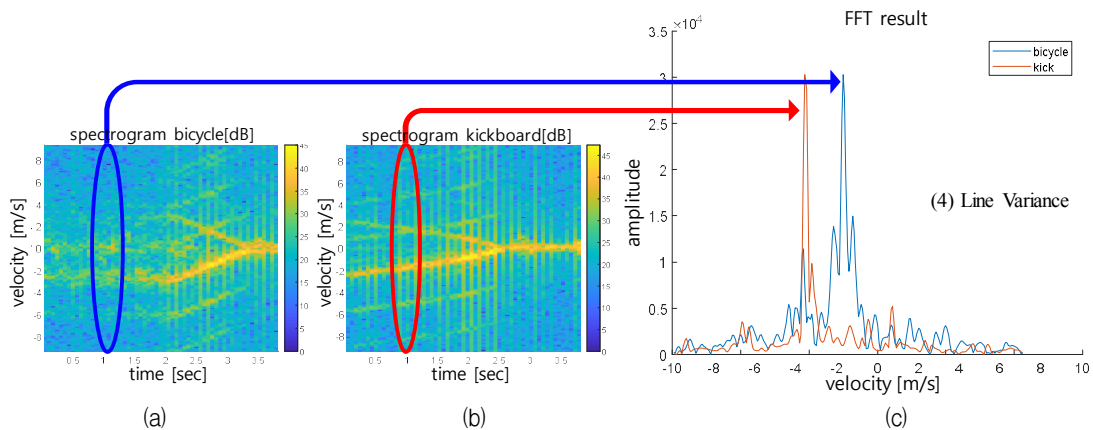


Fig. 4. Variance comparison of a bicycle and a kickboard. (a): Spectrogram of a bicycle. (b): spectrogram of a kickboard. (c): FFT result of short-time signal.

그림 4. 자전거와 전동킥보드의 분산 비교. (a): 자전거 스펙트로그램. (b): 전동 킥보드 스펙트로그램. (c): 단시간 신호의 FFT 결과

다. 그림 1을 보면 타겟의 몸통 속도가 시간이 지날수록 0에 가까워지는 것을 확인 할 수 있으며, 최고 속도는 차가 가장 큰 값을 나타내고, 사람의 최고 속도가 가장 작은 값을 나타내는 것을 확인 할 수 있다. 또한, Torso bandwidth를 특징점으로 사용하기 위해서 매 단위 시간마다 측정되는 몸통 주파수를 이전 단위 시간에서의 몸통 주파수와 비교하여 데이터 수집 시간 동안의 몸통 주파수의 최댓값과 최솟값을 각각 산출한 후, 식(6)과 같이 차이를 구하였다.

$$Feature(2) = \max\{f^*(\tau)\} - \min\{f^*(\tau)\} \quad (6)$$

3. Bandwidth

사람의 움직임은 팔과 다리 운동이, 자전거는 사람의 다리 운동이 수반된다. 이러한 팔과 다리에 의해 발생하는 운동은 미세 도플러 주파수를 생성한다. 본 논문에서 특징으로 제시한 Bandwidth는 몸통 주파수와 미세 도플러 주파수를 포함한 속도의 변화폭을 의미한다. 또한, 미세도플러 주파수를 측정하기 위해서는 몸통 주파수 주변으로 위쪽 포락선과 아래쪽 포락선 총 2개의 포락선을 구해야한다. 대역폭은 식(7)에 표현된 바와 같이 위쪽 포락선의 최댓값과 아래쪽 포락선의 최솟값의 차이로 구해진다.

$$Feature(3) = \max\{Top\ Envelope^*(\tau)\} - \min\{Bottom\ Envelope^*(\tau)\} \quad (7)$$

2개의 포락선을 구하는 과정은 몸통 주파수를 기준으로 위쪽과 아래쪽으로 신호의 크기가 몸통 주파수의 37.5% 이상이 되는 지점을 찾는다. 37.5%의 수치는 실험적으로 구해진 수치이며, 하드웨어 구현에 있어 이진수로 표현이 쉬운 값으로 결정된 수치이다.

타겟이 사람인 경우 포락선이 몸통 주파수 주변으로 명확하게 구해지는 반면에 바퀴가 있는 타겟의 경우 바퀴의 원운동에 의한 속도가 스펙트로그램에 표현된다[11]. 이로 인해, 몸통 주파수 주변으로 명확하게 포락선이 구해지지 않는 특징을 보인다. 그림 1을 보면 바퀴의 반사 면적이 존재하는 타겟의 경우 포락선이 가끔씩 몸통 주파수의 2배가 되는 지점에 잡히는 것을 확인 할 수 있는데, 이는

바퀴의 원운동에 의해 발생하는 현상이다. 이러한 현상으로 인하여 바퀴가 존재하는 타겟의 대역폭은 사람의 대역폭 보다 비교적 큰 값을 갖는다.

4. Line Variance

미세 도플러 주파수가 비교적 큰 값으로 발생하는 사람과 자전거, 미세 도플러 주파수가 비교적 작은 값으로 발생하는 차, 전동 키보드의 차이점은 FFT 윈도우 단위로 입력되는 스펙트로그램의 분산으로 확인할 수 있다. 분산은 미세 도플러 주파수가 몸통 주파수를 주변으로 얼마나 퍼져있는가를 나타내는 지표이다. 따라서 사람과 자전거의 경우 몸통 주파수 주변으로 미세 도플러 주파수가 퍼져있기 때문에 높은 분산 값을 갖고, 전동 키보드와 차는 반대로 작은 분산 값을 갖는다. 그림 4는 자전거와 전동키보드의 스펙트로그램에서 하나의 단위 시간 동안의 푸리에 변환 결과를 2차원 그래프로 표현한 것이다. 그림 4를 통해 자전거의 미세 도플러 주파수가 전동키보드의 미세 도플러 주파수보다 더 넓게 퍼져있는 것을 확인 할 수 있다. 따라서, 해당 특징을 사용하면 속도와 속도의 변화폭이 비슷한 값으로 측정되는 전동키보드와 자전거를 서로 분류할 확률이 높아진다.

스펙트로그램 전체에 대한 분산을 특징으로 사용한다면, 스펙트로그램 전체를 메모리에 저장해야하기 때문에 메모리 사용량이 증가한다. 또한, 데이터 양의 증가로 인하여 데이터 처리 시간도 증가하는 현상이 발생한다. 따라서, 본 논문에서는 아래의 식(8)과 식(9)를 통해 스펙트로그램 전체가 아닌 FFT 윈도우 단위 스펙트로그램 데이터의 분산 값을 구하였다. 여기서, N_F 는 고속 푸리에 변환 포인트 수를 의미한다.

$$\bar{S}(\tau) = \frac{1}{N_F} \sum_{f=1}^{N_F} S(\tau, f) \quad (8)$$

$$var(\tau) = \frac{1}{N_F} \sum_{f=1}^{N_F} \{S(\tau, f) - \bar{S}(\tau)\}^2 \quad (9)$$

최종적으로 식(10)과 같이 N_T 초 동안 구한 분산 값들의 평균값을 구해서 특징으로 사용하였다.

$$Feature(4) = \frac{1}{N_T} \sum_{\tau=1}^{N_T} var(\tau) \quad (10)$$

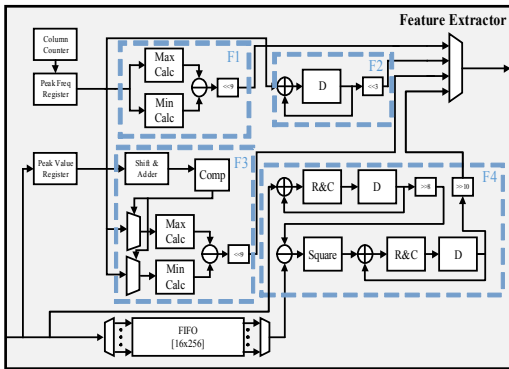


Fig. 5. Block diagram of proposed Feature Extractor.
그림 5. 제안하는 특징점 추출기 블록도

IV. 하드웨어 구조 설계 및 구현

본 논문에서 제안하는 특징점 추출기는 그림 5와 같이 FIFO (first input first output)와 4가지 특징을 추출하는 연산기들로 구성 되어있다. Bandwidth의 경우 스펙트로그램 열중 가장 큰 값을 갖는 데이터의 37.5%에 해당하는 주파수를 특징으로 사용하며, Line variance의 경우 분산을 구하는 과정에서 평균값을 연산해야하기 때문에 FFT 윈도우 단위 스펙트로그램 데 바탕으로 특징점 추출이 이루어진다. 특징점 추출기의 타이밍 다이어그램인 그림 6에서 보여지듯이 peak value와 peak frequency 같은 경우 스펙트로그램 한 줄의 데이터를 모두 읽은 후에 출력된다. 또한, FIFO의 출력 데이터도 같은 타이밍에 출력되기 때문에, 이를 바탕으로 특징점 추출을 진행 한다. 최종적으로 고속 푸리에 변환 포인트 수가 256 포인트이고, 입력 신호가 윈도우 함수로 59개의단시간 신호로 분할되었을 경우에 4 개의 특징으로 구성된 특징 벡터가 출력되기 위해서는 총 15,540 cycle이 소요 된다.

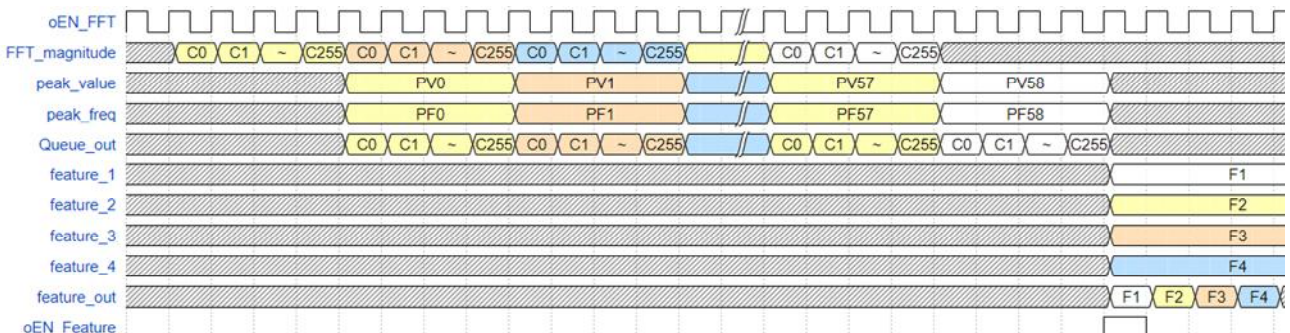


Fig. 6. Timing diagram of proposed Feature Extractor.
그림 6. 제안하는 특징점 추출기 타이밍도

V. 하드웨어 구현 결과 및 실험 결과

제안된 특징점 추출기를 Verilog HDL을 이용하여 RTL 설계 후 Xilinx Zynq-7000 FPGA를 이용하여 검증 및 구현하였다. 표 1은 기존의 Kim-Ling 특징점 추출 기법과 면적, 메모리 요구량에 대한 비교 결과를 보여준다[3-4]. Slice의 경우 추가적인 FFT 블록을 사용하지 않기 때문에 감소되었음을 확인할 수 있고, 메모리 요구량은 스펙트로그램 전체를 저장하는 대신 FFT 윈도우 단위 스펙트로그램만을 저장하여 크게 감소되었음을 확인할 수 있다. 결과적으로, 기존 논문 대비 유사한 분류 정확도 성능을 보이며, slice는 58.3% 감소하고, 메모리 사용량은 98.3% 감소함을 확인하였다.

Table 1. Comparison for the Feature Extractor implementation results based on Zynq-7000 FPGA.

표 1. Zynq-7000 기반 특징점 추출기 구현 결과 비교

		Kim-Ling[3-4]	Proposed	Reduction(%)
Area	Slice	228	95	58.3%
	Mem	241K	4K	98.3%
Classification Accuracy		94.2%	93.4%	-

제안된 특징점 추출기 기반 객체 분류 성능을 확인하기 위해 그림 7과 같이 실외 공간에서 실험이 수행되었다. 레이더를 향해 오는 차, 자전거, 사람 그리고 전동 키펠드의 데이터를 각각 120개씩 총 480개 확보하였으며, 수집한 데이터를 바탕으로 타겟 분류는 RCE 신경망 알고리즘을 사용하였다. 또한, 5겹 교차 검증으로 성능 평가를 진행하였으며, 표 2에 나타난 것과 같이 평균 분류 결과 정확도가 93.4%인 것을 확인하였다.



Fig. 7. Experiment environment.
그림 7. 실험 환경

Table 2. Classification resultss.
표 2. 분류 결과

Predicted \ True	Car	Bicycle	Human	Kickboard
Car	93.3%	0.1%	0%	4.2%
Bicycle	0%	91.7%	1.1%	6%
Human	0%	1.4%	98.9%	0%
Kickboard	6.7%	6.8%	0%	89.8%

VI. 결론

본 논문에서는 보안 감시용 레이더 시스템을 위한 특징점 추출기가 제안되었다. 제안하는 특징점 추출기를 Zynq-7000 FPGA를 이용하여 구현하였으며, 기존 연구와 비교 결과 slice 개수를 58.3% 감소 가능하며, 메모리 요구량은 98.3% 감소 가능성을 확인하였다. 제안된 특징점 추출기 기반 보안 감시용 레이더 시스템의 객체 분류 성능을 확인하기 위해 FPGA 시스템이 구현되었으며, 실험 결과 약 93.4%의 분류 정확도를 지원 가능성을 확인하였다.

References

[1] P. Burnos, J. Gajda, P. Piwowar, R. Sroka, M. Stencel, and T. Zeglen, "Measurements of Road Traffic Parameters Using Inductive Loops and Piezoelectric Sensors," *Metrol. Meas. Syst.*, Vol.14, No.2, pp.187-203, 2007.

[2] S. Nag, M. A. Barnes, T. Payment, G. Holladay, "Ultrawideband through-wall radar for detecting the motion of people in real time," *Proc. SPIE Radar Sens. Technol. Data Vis.*, Vol.4744, pp.48-57. 2002. DOI: 10.1117/12.488285

[3] Y. Kim and H. Ling, "Human Activity Classification Based on Micro-Doppler Signatures Using a Support Vector Machine," in *IEEE*

Transactions on Geoscience and Remote Sensing, Vol.47, No.5, pp.1328-1337, 2009.

DOI: 10.1109/TGRS.2009.2012849

[4] S. Bjorklund, T. Johansson and H. Petersson, "Target classification in perimeter protection with a micro-Doppler radar," *2016 17th International Radar Symposium (IRS)*, pp.1-5, 2016.

DOI: 10.1109/IRS.2016.7497363

[5] Y. Kim, S. Ha and J. Kwon, "Human Detection Using Doppler Radar Based on Physical Characteristics of Targets," in *IEEE Geoscience and Remote Sensing Letters*, Vol.12, No.2, pp. 289-293, 2015. DOI: 10.1109/LGRS.2014.2336231

[6] L. Du, L. Li, B. Wang and J. Xiao, "Micro-Doppler Feature Extraction Based on Time-Frequency Spectrogram for Ground Moving Targets Classification With Low-Resolution Radar," in *IEEE Sensors Journal*, Vol.16, No.10, pp.3756-3763, 2016. DOI: 10.1109/JSEN.2016.2538790

[7] J. L. Geisheimer, W. S. Marshall and E. Grenaker, "A continuous-wave (CW) radar for gait analysis," *Conference Record of Thirty-Fifth Asilomar Conference on Signals, Systems and Computers (Cat.No.01CH37256)*, Pacific Grove, CA, USA, Vol.1, pp.834-838, 2001.

DOI: 10.1109/ACSSC.2001.987041

[8] W. Jeong, M. Kim, J. Cho, and Y. Jung, "Design of Gas Classifier Based On Artificial Neural Network," *Journal of IKEEE*, Vol.22, No.3, pp.700-705, 2018.

DOI: 10.7471/ikeee.2018.22.3.700

[9] Cho, J.; Jung, Y.; Lee, S.; Jung, Y. "VLSI Implementation of Restricted Coulomb Energy Neural Network with Improved Learning Scheme," *Electronics* 2019. DOI: 10.3390/electronics8050563

[10] Kim, M.; Cho, J.; Lee, S.; Jung, Y. "IMU Sensor-Based Hand Gesture Recognition for Human-Machine Interfaces," *Sensors* Vol.19, No.18, pp.3827, 2019. DOI: 10.3390/s19183827

[11] G. Duggal, S. Vishwakarma, K. V. Mishra, and S. S. Ram, "Doppler-resilient 802.11ad-based ultra-short range automotive radar," arXiv:1902.01306, 2019.

BIOGRAPHY

Yeongung Choi (Member)

2014~present : BS degree in School of Electronics and Information Engineering, Korea Aerospace University.

Jaehyung Lim (Member)

2014~present : BS degree in School of Electronics and Information Engineering, Korea Aerospace University.

Geonwoo Kim (Member)

2014~present: BS degree in School of 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.

2005~2008 : Senior, Samsung Electronics

2008~present : Professor, School of Electronics and Information Engineering, Korea Aerospace University