

실내 보안 응용을 위한 사람 감지 레이더 시스템의 설계 및 구현

Design and Implementation of Human-Detecting Radar System for Indoor Security Applications

장 대 호*, 김 현*, 정 윤 호*

Daeho Jang*, Hyeon Kim*, Yunho Jung*

Abstract

In this paper, the human detecting radar system for indoor security applications is proposed, and its FPGA-based implementation results are presented. In order to minimize the complexity and memory requirements of the computation, the top half of the spectrogram was used to extract features, excluding the feature extraction techniques that require complex computation, feature extraction techniques were proposed considering classification performance and complexity. In addition, memory requirements were minimized by designing a pipeline structure without storing the entire spectrogram. Experiments on human, dog and robot cleaners were conducted for classification, and 96.2% accuracy performance was confirmed. The proposed system was implemented using Verilog-HDL, and we confirmed that a low-area design using 1140 logics and 6.5 Kb of memory was possible.

요 약

본 논문에서는 실내 보안 응용을 위한 사람 감지 레이더 시스템을 제안하고, 이의 FPGA 기반 설계 및 구현 결과를 제시하였다. 연산의 복잡도와 메모리 요구량을 최소화하기 위해 스펙트로그램의 상측 절반만 특징점 추출에 사용하였으며, 복잡한 연산이 필요한 특징점 추출기법을 배제하고, 분류 성과와 연산 복잡도를 고려한 효율적인 특징점 추출기법이 제안되었다. 또한, 전체 스펙트로그램에 대한 저장이 불필요한 파이프라인 구조로 설계하여 메모리 요구량을 최소화하였다. 제안된 시스템의 분류 학습을 위해 사람, 개, 로봇 청소기에 대한 실험이 수행되었고, 96.2%의 정확도 성능을 확인하였다. 제안된 시스템은 Verilog-HDL을 이용하여 구현되었으며, 1140개의 logic과 6.5 Kb의 메모리를 사용하는 저면적 설계가 가능함을 확인하였다.

Key words : radar target classification, SVM, feature extraction, human detecting

* 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.2020-0-00201) and CAD tools were supported by IDEC.

Manuscript received Aug. 31, 2020; revised Sep. 4, 2020; accepted Sep. 21, 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 주거의 안정성과 특정 공간 내의 보안 유지를 위해 침입자를 감지하는 보안 및 감시 시스템이 필수적이다. 특히 24시간 동작하는 감시 시스템 특성상 저면적, 저전력의 시스템이 필요하다. 기존의 보안 시스템에서는 CCTV 카메라, 적외선 센서, 마이크로웨이브 센서, 레이더 등 다양한 센서들이 활용되고 있다[1]. 하지만, 이러한 센서들은 어두운 환경에서 대상을 감지하지 못하거나, 사람이 아닌 다른 물체의 움직임을 감지하여 오작동하는 경우가 많다. 특히 CCTV의 경우 사람

이 직접 화면을 감시하여야 한다는 단점이 있다[2]. 그에 반면 전자기파를 사용하여 표적을 탐지하는 레이더는 외부 환경에 영향을 적게 받고 어두운 환경에서도 대상을 감지할 수 있다는 장점이 있다[3]. 또한, 대상을 감지하는 것뿐만 아니라 사람의 다양한 동작이나 미세한 움직임を検출할 수 있어서 사람과 다른 물체들을 분류하는 타겟 인식에 관한 연구도 활발히 진행되고 있다[3-5].

레이더 센서는 신호의 변조 방식에 따라 펄스형(Pulse type)과 연속파형(CW; continuous wave)으로 나누어진다. 펄스형은 짧은 펄스의 반사를 통한 전파의 지연시간을 이용하며 대상의 움직임과 위치 정보를 얻을 수 있다. 연속파형은 특정 주파수의 전파를 계속 보내고 반사되는 신호와 주파수 차이를 측정하여 물체의 움직임을 감지한다. 이러한 주파수 차이를 도플러 주파수라고 하며 대상의 속도 정보를 얻을 수 있다[6]. 본 논문에서는 속도 정보를 이용해 대상을 분류하기 위해 CW레이더를 사용한다.

CW레이더에서 얻은 도플러 주파수 신호처리를 위해 흔히 사용하는 FFT(Fast Fourier Transform)로 시간 영역을 주파수 영역으로 변환하면 시간에 대한 정보는 사라지기 때문에, 각 주파수에 해당하는 신호가 어느 시점에서 존재하였는지 확인할 수 없다. 이것을 해결하기 위한 방법으로 STFT(Short-Time Fourier Transform)를 사용하여 시간과 주파수에 대한 스펙트로그램(Spectrogram)을 얻을 수 있다[7]. 스펙트로그램은 대상마다 각각의 특징을 가지고 있어서 사람과 다른 물체의 특징을 비교하여 대상을 구분할 수 있다.

하지만 대상을 분류하기 위해 후처리 되지 않은 레이더 신호를 직접 사용하거나 STFT를 통해 얻어진 스펙트로그램 전체를 사용하게 되면 분류 알고리즘의 복잡도와 메모리 요구량이 높아진다[8]. 따라서 도출된 스펙트로그램에서 특징으로 나타나는 매개변수를 추출하여 분류를 진행하는 것은 알고리즘의 복잡도를 줄이고 메모리 사용량을 줄이는 등 경량화에 있어서 필수적이다[8].

레이더를 응용한 분류 알고리즘으로는 KNN(K-Nearest Neighbor), MLP(Multi-Layer Perceptron), SVM(Support Vector Machine) 등 다양한 기계학습 기반의 알고리즘이 주로 사용된다[10]. 이중 KNN은 데이터의 양이 많아지면 분류 속도가 느리고, MLP

는 학습 시간이 오래 걸리고 과적합 문제가 발생할 수 있다는 단점이 있다[9-10]. 이에 반해, SVM은 간단한 구조를 가짐에도 불구하고 높은 분류 성능을 가진다[10].

본 논문에서는 실내 보안 응용을 위해 최소한의 메모리와 연산기를 사용하는 STFT 신호처리 및 특징점 추출기, SVM 분류기의 하드웨어 구조를 제안한다. 또한, 실험을 통해 얻은 사람, 개, 로봇 청소기 데이터의 분류를 위하여 높은 분류 성능을 가지는 특징점 추출 방법과, 이를 낮은 복잡도의 SVM 이진 분류 알고리즘을 통하여 사람과 그 외의 데이터를 분류한 결과를 제시한다.

본 논문의 구성은 다음과 같다. 2장에서는 제안된 시스템의 개요 및 알고리즘에 대해 설명하며, 3장에서는 본 논문에서 제안하는 시스템의 실험내용과 결과에 관해서 설명한다. 또한, 4장에서는 하드웨어 구조 설계 및 구현에 대해 기술한 뒤, 마지막으로 5장에서 본 논문의 결론을 맺는다.

II. 제안된 시스템의 개요 및 알고리즘

제안된 시스템의 전체적인 진행 과정은 그림 1과 같다. CW레이더로 측정된 신호를 STFT를 통해 스펙트로그램을 얻고, 이 스펙트로그램으로부터 다양한 특징점을 추출 후 SVM 이진 분류기를 통해 사람인지 아닌지 분류한다.

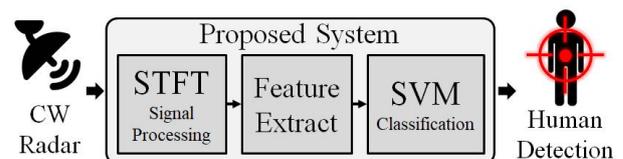


Fig. 1. Flowchart of proposed system.

그림 1. 제안된 시스템 흐름도

1. STFT Signal Processing

CW레이더는 도플러효과에 의해 나타나는 송신 주파수 $f_{transmit}$ 와 수신 주파수의 차이인 도플러 주파수 $f_{doppler}$ 를 측정한다. 측정된 도플러 주파수를 이용해 대상의 속도를 식(1)과 같이 계산할 수 있다. v 는 대상이 레이더를 향해 다가오는 속도, c 는 전파의 속도이다.

$$v \approx \frac{c}{2f_{transmit}} f_{doppler} \quad (1)$$

스펙트로그램은 레이더 신호에 STFT를 사용하여 얻어진다. 윈도우 함수를 적용해 레이더 신호를 단시간 신호(Short-time signal)로 분할하고, 분할된 단시간 신호에 대해 FFT를 적용하여 시간 변화에 따른 도플러 주파수를 분석할 수 있다. 이렇게 얻어진 FFT 결과를 시간 축으로 이어 붙이면 그림 2와 같은 스펙트로그램을 얻을 수 있다.

가로축은 시간, 세로축은 속도를 나타내며, 신호의 세기는 색으로 표현한다. 진한 빨간색에 가까울수록 높고, 파란색에 가까울수록 낮은 신호의 세기를 나타낸다.

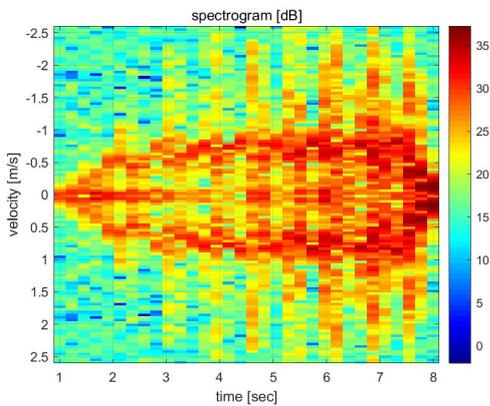


Fig. 2. Spectrogram by STFT.
그림 2. STFT에 의한 스펙트로그램

2. Feature Extraction

타겟 종류별 스펙트로그램은 그림 3과 같다. 면적이 가장 넓은 몸통의 주파수의 세기가 가장 강하게 나타나고, 팔다리 움직임에 의해 미세 도플러 주파수(micro-Doppler frequency)가 나타난다. 개는 사람보다 다리 움직임이 빨라 그림 3(b)에서 개의 스펙트로그램은 미세 도플러의 시간 간격이 그림 3(a)의 사람 스펙트로그램보다 더 촘촘히 나타난다. 그림 3(c)는 다리 움직임이 없는 로봇 청소기의 스펙트로그램이며, 미세 도플러 주파수가 나타나지 않는다. 따라서 본 논문에서는 이에 기반한 5가지 효율적인 특징점 추출 기법을 제안한다.

제안하는 첫 번째 특징은 보폭의 주기(Period of Stride)이다. 사람의 다리 움직임의 주기는 다리 길이가 짧은 개와 구분된다. 발을 한걸음 움직인 후 다음 발을 움직일 때까지 걸리는 시간은 다리 길이가 긴 사람이 다리 길이가 짧은 개보다 더 길게 나타난다. 이는 스펙트로그램 상에서 미세 도플러의 시간 간격으로 확인할 수 있다. 그림 4에서 세로로

표시된 미세 도플러의 시간 간격의 평균으로 계산한다.

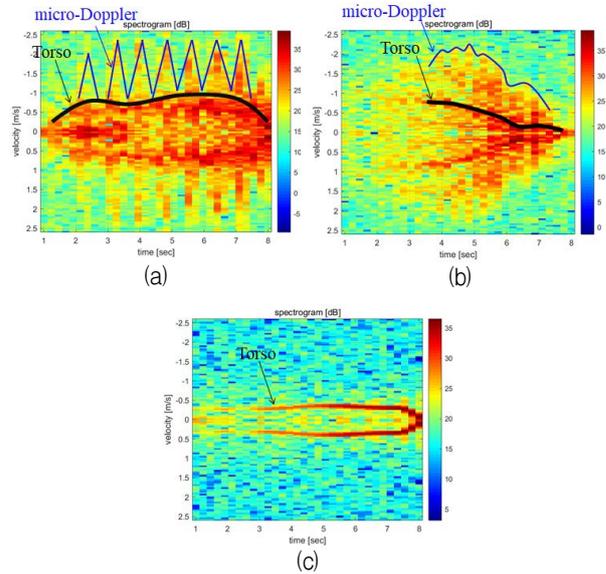


Fig. 3. Spectrogram : (a) a human, (b) a dog, (c) a robot cleaner.

그림 3. 스펙트로그램 : (a) 사람, (b) 개, (c) 로봇 청소기

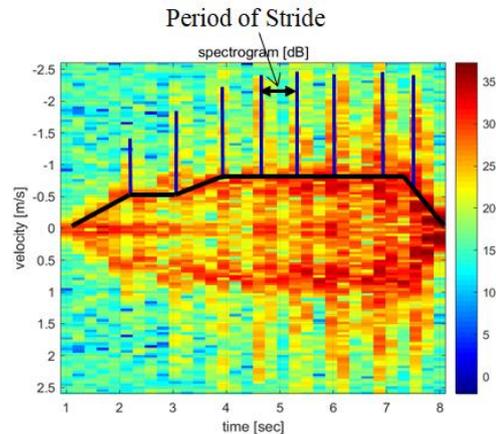


Fig. 4. Period of Stride.

그림 4. 보폭의 주기

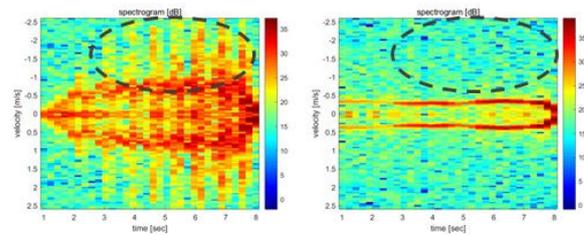


Fig. 5. Count of Stride : (a) a human, (b) a robot cleaner.

그림 5. 보폭의 횟수 : (a) 사람, (b) 로봇 청소기

두 번째 제안하는 특징은 보폭의 횟수(Count of Stride)이다. 그림 5와 같이 사람이나 개와 달리 다

리가 없는 로봇 청소기는 다리 움직임에 의한 미세 도플러가 나타나지 않는다. 이는 다리가 없는 물체와 사람을 구분하는 특징으로 적합하다.

세 번째 제안하는 특징은 레이더 반사 면적(RCS : Radar cross section)이다. 레이더 반사 면적은 전자기파가 대상에서 반사되는 에너지의 총량이다. 대상의 크기에 따라 반사되는 면적이 달라지며, 크기가 큰 대상일수록 크게 나타난다. 따라서 RCS는 사람, 개, 로봇 청소기 순으로 크게 나타난다. 스펙트로그램에서 임계값 이상의 데이터를 모두 더하여 계산한다.

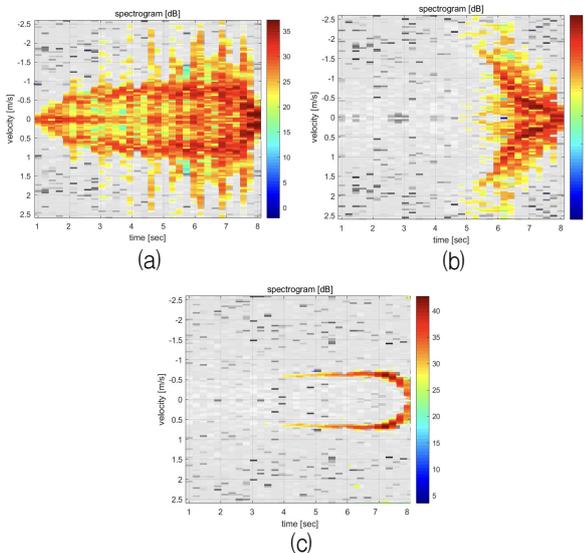


Fig. 6. RCS : (a) human, (b) dog, (c) robot cleaner.
그림 6. 레이더 반사 면적 : (a) 사람, (b) 개, (c) 로봇 청소기

제안하는 네 번째 특징은 피크 주파수(Peak frequency)와 몸통 주파수(Torso frequency)의 차이이다. 피크 주파수는 미세 도플러 주파수의 최댓값이며, 다리의 스윙 속도를 의미한다. 몸통 속도와 다리의 스윙 속도 차이는 대상의 다리 길이에 의해 결정된다. 개는 사람보다 다리가 더 짧아 몸통의 속도와 다리의 스윙 속도 차이가 더 작게 나타난다. 따라서 스펙트로그램 상에서 몸통의 속도를 나타내는 몸통 주파수와 다리의 스윙 속도를 나타내는 피크 주파수의 차이를 계산하여 사람과 개를 구분하는 특징으로 사용한다.

다섯 번째 제안하는 특징은 피크 주파수의 분산이다. 사람의 스펙트로그램의 경우 팔다리 움직임에 의한 미세도플러가 주기적으로 나타나기 때문에 팔다리 움직임이 없는 물체에 비해 피크 주파수

의 변화폭이 크다. 따라서 분산 값도 크게 나타난다. 이는 사람을 분류하는 특징으로 적합하다. 하지만 전체 스펙트로그램에 대해 피크 주파수를 계산한 후 다시 평균을 구하고 분산을 계산하는 과정은 하드웨어 구조적으로 복잡해진다는 단점이 있다.

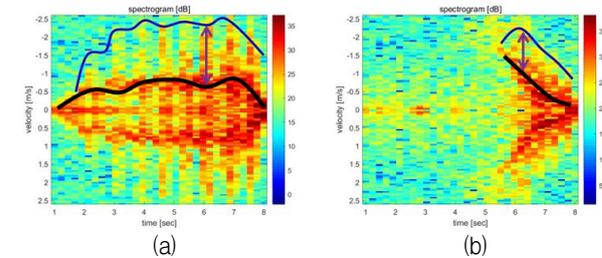


Fig. 7. Difference of Peak frequency and Torso frequency : (a) human, (b) dog.
그림 7. 최고주파수와 몸통 주파수의 차이 : (a) 사람, (b) 개

3. SVM Classification

특징 추출이 끝나면 SVM을 이용한 분류를 진행한다. SVM은 그림 8과 같이 두 클래스를 구분 짓는 초평면(hyper-plane)을 정의하고 해당 초평면을 기준으로 두 클래스 사이의 margin을 최대화하여서 이진 분류를 수행한다[11]. 추출한 특징들로 만들어진 벡터 중 초평면과 가장 가까이 있는 벡터들을 support vector라고 하며, 초평면으로부터 support vector까지의 거리의 두 배를 margin이라 하고, b는 bias를 의미하는 상수이다. SVM 학습은 margin을 최대화할 수 있는 support vector를 찾는 과정이다.

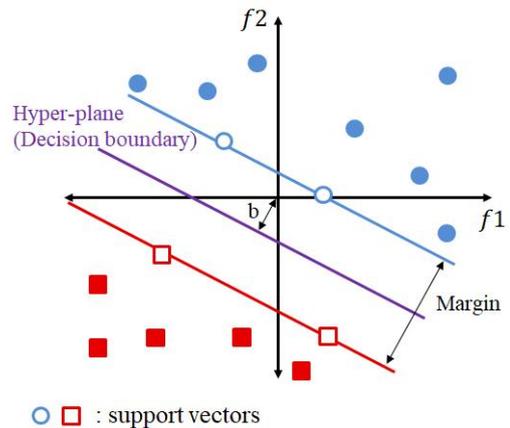


Fig. 8. Hyperplane and support vector of SVM.
그림 8. SVM의 초평면과 서포트 벡터

학습을 통해 초평면이 결정되면 분류를 위한 parameter를 얻을 수 있다. 얻어진 parameter를 이용한 분류식은 식 (2)와 같다. \mathbf{x} 는 분류할 입력 벡

터이고 평균 μ 와 표준편차 σ 로 표준화 후 선형 예측 변수 β 를 곱하고 kernel scale s 로 나눈 후 bias b 를 더하여 분류 점수를 계산한다. 계산된 분류 점수가 양수 또는 음수임에 따라 클래스를 분류한다.

$$f(\mathbf{x}) = \left(\frac{\mathbf{x} - \mu}{\sigma}\right) \times \frac{\beta}{s} + b \quad (2)$$

III. 제안된 시스템의 분류 성능 평가

제안된 시스템의 SVM 학습을 위한 데이터 확보 및 분류 성능을 확인하기 위해 그림 9와 같이 실내외 환경에서 실험이 진행되었다. 사람, 개, 로봇 청소기의 데이터를 각각 235, 54, 155개씩 총 444개 확보하였으며, 학습을 위한 training set으로 각각 215, 44, 140개를 사용하였고, 검증을 위한 test set으로 각각 20, 10, 15개를 사용하였다.

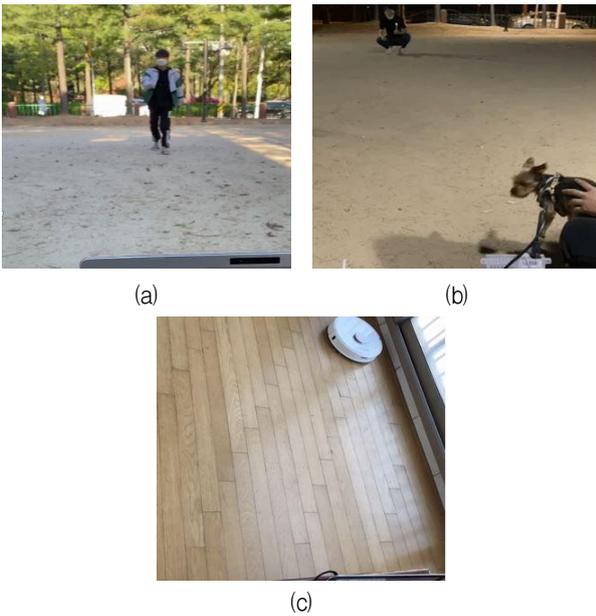


Fig. 9. Experiment environment : (a) outdoor human experiment, (b) outdoor dog experiment, (c) indoor robot cleaner experiment.
 그림 9. 실험 환경 : (a) 실외 사람실험, (b) 실외 개 실험, (c) 실내 로봇 청소기 실험

그림 10은 실험 대상별 추출한 특징값을 비교한 것으로 사람, 개, 로봇 청소기 각각 40개, 총 120개의 데이터를 사용하였다. 40개 각각의 데이터에 해당 특징을 계산하여 그래프로 나타내었다. 그림 10(a)는 첫 번째 특징을 계산한 그래프이며, 사람이

가장 높은 값이 나오고 로봇 청소기에서는 0의 값이 나타나는 것을 볼 수 있다. 그림 10(b)는 두 번째 특징을 계산한 그래프이며, 사람의 발걸음 수가 카운트되지만, 개의 경우 발걸음이 너무 빨라 제대로 카운트되지 않는 모습을 보였다. 그림 10(c)와 그림 10(d)는 각각 세 번째, 네 번째 특징이며 사람과 다른 대상이 확실히 구분되므로 분류 특징으로 적합하다. 그림 10(e)는 다섯 번째 특징을 나타낸 그래프이며, 로봇 청소기와의 구분은 확실하지만, 개와 사람의 구분이 확실하지 않은 모습을 보였다.

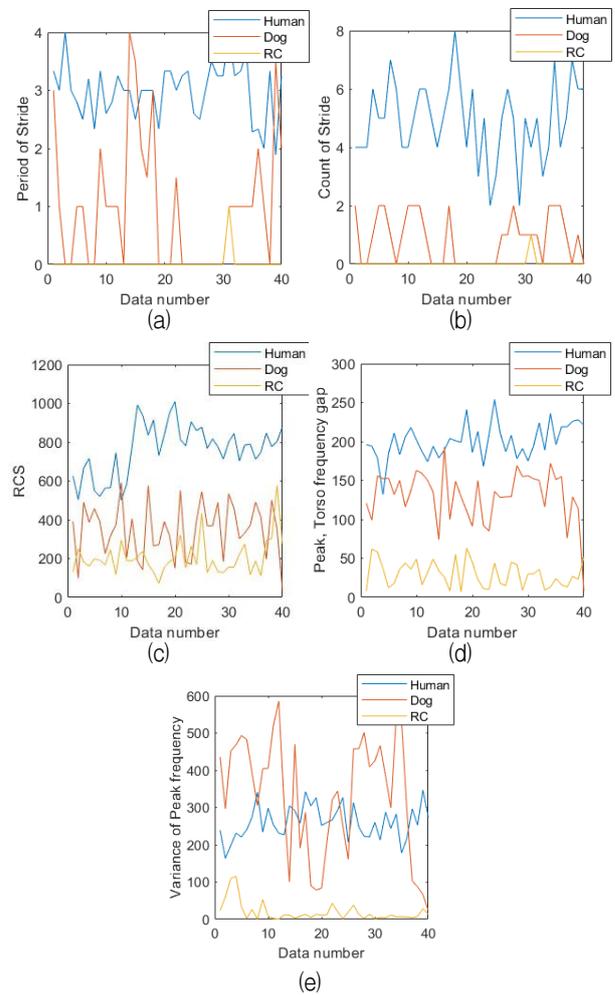


Fig. 10. Feature values comparison : (a) Feature 1, (b) Feature 2, (c) Feature 3, (d) Feature 4, (e) Feature 5

그림 10. 실험 대상별 특징값 비교 : (a) 특징 1, (b) 특징 2, (c) 특징 3, (d) 특징 4, (e) 특징 5

5가지 특징 중 분류에 사용할 특징을 결정하기 위해 정확도를 확인하는 실험을 진행하였다. 표 1은 분류에 사용된 특징 개수별 정확도의 평균을 나타

낸 것이다. 5가지 특징을 모두 사용한 경우 97.2%의 정확도를 보였고, 4가지 특징을 사용한 경우 96.2%, 3가지 특징을 사용한 경우 95.9%, 2가지 특징을 사용한 경우 93.5%의 정확도를 보였다. 많은 특징을 사용할수록 더 높은 정확도를 보이지만 연산복잡도가 늘어난다. 하드웨어 구현을 위해 연산복잡도와 분류 정확도를 고려하여 연산복잡도가 가장 큰 다섯 번째 특징을 제외한 4가지 특징만을 사용함으로써 낮은 연산복잡도로 좋은 성능을 갖도록 설계하였다.

Table 1. Average accuracy for each feature.

표 1. 사용 특징별 평균 정확도

Number of features used	Average Accuracy (%)
5	97.2
4	96.2
3	95.9
2	93.5

표 2는 분류 알고리즘에 따른 정확도를 비교한 것이다. 제안된 4가지 특징을 사용하여 실험하였을 때 SVM이 결정 트리, KNN 구조와 비교하여 96.2%로 가장 높은 정확도를 보였다.

Table 2. Accuracy for Various Classification Algorithms.

표 2. 분류 알고리즘별 정확도

Classification Algorithm	Accuracy (%)
SVM	96.2
Decision Tree	93.5
KNN	94.7

IV. 하드웨어 구조 설계 및 구현

본 논문에서 제안하는 시스템의 하드웨어 구조는 그림 11과 같다. 크게 STFT, Feature Extractor, SVM Classifier 3개의 블록으로 구성되어있다. STFT는 데이터 메모리와 Single Butterfly 구조의 FFT블록, 윈도우 함수를 저장한 Hanning Window ROM, DC성분 제거를 위한 DC Remover로 이루어져 있으며, 메모리에서 데이터를 읽고 DC성분을 제거한 후 윈도우함수를 곱하여 데이터를 분할한다. 분할된 데이터에 대한 7 스테이지의 FFT 연산 후 출력

스테이지에서 Feature Extractor로 FFT결과를 전달한다. 계산된 FFT 결과 값은 Feature Extractor에서 4가지 특징계산에 병렬로 사용된다. 마지막 분할 데이터까지 특징계산이 완료되면 SVM Classifier 블록에서 분류를 위한 연산을 수행하고, 분류 결과로 1 또는 0을 출력하여 사람인지 아닌지를 분류한다.

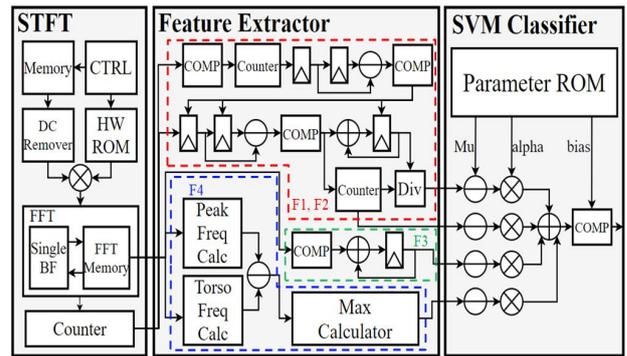


Fig. 11. Block diagram of proposed system.

그림 11. 제안된 감시 시스템의 블록도

사용된 레이더에서 실숫값의 데이터만 나오기 때문에 FFT 결과가 대칭으로 나온다. 따라서 스펙트로그램 또한 상하 대칭으로 나타나기 때문에, 메모리 사용량을 줄이기 위해 특징점 계산에는 상측 절반만 사용하였다. 또한, STFT결과로 얻어지는 스펙트로그램을 메모리에 저장하지 않고 파이프라인 구조를 사용하여 Feature Extractor에서 재사용함으로써 추가적인 메모리 사용 없이 구현 하였다.

제안된 시스템은 Verilog HDL을 이용하여 설계 되었으며 Altera Cyclone V 5CGXFC7C7F23C8 FPGA를 이용하여 검증 및 구현되었다. FPGA 기반 구현 결과, 1140개의 logic과 6.5 Kb의 메모리, 15개의 DSP Block만을 사용하여 구현 가능함을 확인하였다. 제안된 시스템의 논리 게이트 수를 확인하기 위해 TSMC 40 nm CMOS 표준 셀 라이브러리를 활용하여 논리 합성이 수행되었고, 합성결과 총 게이트 수는 66K임이 확인되었다. 표 3은 리소스 사용에 대한 요약이며, 표 4는 블록별 리소스 사용 및 gate 수를 나타낸다. 또한, 최대 동작 주파수 104.79 MHz로 동작 가능함을 확인하였으며, 제안된 설계의 지연시간은 (latency) 33,952 cycle로, 한 물체를 분류하는데 약 0.324 ms의 짧은 시간으로 실시간 분류가 가능하다.

Table 3. Hardware Resources.

표 3. 하드웨어 리소스

Resource		Usage
Altera Cyclone V FPGA	Logic utilization	1140
	Combinational ALUTs	1294
	Logic registers	2048
	Block memory	6.5 Kb
	DSP Blocks	15
TSMC 40nm CMOS Process	Gate Count	66K

Table 4. Hardware Resource per each block.

표 4. 블록별 하드웨어 리소스

Block	STFT	Feature Extractor	SVM Classifier	TOP
Combinational ALUTs	955	247	92	1294
Logic Registers	1500	334	214	2048
Memory	6.4 Kb	0	81 bit	6.5 Kb
DSP	11	0	4	15
Logic Gates	49K	9K	8K	66K

V. 결론

본 논문에서는 실내 보안 응용을 위한 레이더 신호처리 및 분류 알고리즘과 하드웨어 구현 결과가 제안되었다. STFT를 사용한 신호처리와 효율적인 분류를 위한 특징점 추출 기법, SVM을 사용한 분류 알고리즘을 제안하였고, 분류 성능 평가를 위한 실험 및 시뮬레이션을 하였다. 4가지 특징을 사용한 실험 결과 약 96.2%의 분류 정확도를 보였다. 또한, 제안된 시스템의 하드웨어 구현을 위해 Verilog HDL을 이용하여 설계하였고, 6.5Kb의 메모리와 1140개의 Logic을 사용하여 0.324ms의 짧은 지연시간으로 실시간 분류가 가능한 저면적 고효율의 시스템을 설계하였다.

References

[1] S. Oh, S. Moon, S. Choi, "Intelligence Security and Surveillance System in Sensor Network Environment Using Integrated Heterogeneous Sensors" *Korea Institute Of Communication Sciences*, Vol.

38C, No.07, pp.551-562, 2013.

DOI: 10.7840/kics.2013.38.c.7.551

[2] H. Shin, B. Han, D. Choi and C. Oh, "Implementation of a Monitoring System Using a CW Doppler Radar," *The Journal of Korea Institute of Electronics Engineers*, Vol.19, No.12, pp.2911-2916, 2015.

DOI: 10.6109/jkiice.2015.19.12.2911

[3] E. Hyun, Y. Jin, "Machine Learning based Pedestrian Indication Scheme for Automotive Radar System," *The Korean Society Of Automotive Engineers*, Daegu : DGIST, pp.684-685, 2019.

[4] K. Baik, B. Jang, "Hand Gesture Classification Using Multiple Doppler Radar and Machine Learning", *The Journal of Korean Institute of Electromagnetic Engineering and Science*, Vol.28, No.1, pp.31-41, 2017. DOI: 10.5515/kjkiees.2017.28.1.33

[5] S. Hong, Y. Yi, J. Jo, S. Lee, B. Seo, "Automatic Classification of Radar Signals Using CNN," *The Journal of Korean Institute of Electromagnetic Engineering and Science*, Vol.30, No.2, pp.132-140, 2019.

DOI: 10.5515/jkjiees.2019.30.2.132

[6] B. Nam, K. Chae, "Design of a K-band CW Radar Transceiver," *Korea Academy Industrial Cooperation Society*, Vol.10, No.7, pp.1532-1535, 2009. DOI: 10.5762/kais.2009.10.7.1532

[7] N. Jung, C. Park, J. Lee, Y. Park, S. Shin, "A Study on the Application of TEO and STFT Signal Processing Techniques for Detection of Electric Railway Contact Loss" *The Transactions of the Korean Institute of Electrical Engineers*, Vol.67, No.11, pp.1530-1535, 2018.

DOI: 10.5370/kiee.2018.67.11.1530

[8] Y. Choi, J. Lim, G. Kim, Y. Jung, "Design of Area-efficient Feature Extractor for Security Surveillance Radar Systems" *Institute of Korean Electrical and Electronics Engineers*, Vol.24, No.1, pp.200-207, 2020. DOI: 10.7471/ikeee.2020.24.1.200

[9] E. A. Zanaty, "Support Vector Machines (SVMs) versus Multilayer Perception (MLP) in data classification," *Egyptian Informatics Journal*, 13, pp.177-183, 2012. DOI: 10.1016/j.eij.2012.08.002

[10] Vishal A. Naik and Apurva A. Desai, "Online handwritten Gujarati character recognition using SVM, MLP, and K-NN," *8th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, 2017.

DOI: 10.1109/icccnt.2017.8203926

[11] J. Paik, H. Kim, J. Lee, "SVM based spectrum sensing of 5 GHz weather radar," *The Institute of Electronics and Information Engineers*, pp. 276-278, 2019.

BIOGRAPHY

Daeho Jang (Member)



2015~present : BS degree course in School of Electronics and Information Engineering, Korea Aerospace University.

Hyeon Kim (Member)



2019 : BS degree in School of Electronics and Information Engineering, Korea Aerospace University.

2019~present : MS degree course 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.

2005~2007 : 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