

논문 2018-13-33

소형 무인 항공기 탐지를 위한 인공 신경망 기반 FMCW 레이다 시스템

(Neural Network-based FMCW Radar System for Detecting a Drone)

장 명 재, 김 순 태*
(Myeongjae Jang, Soontae Kim)

Abstract : Drone detection in FMCW radar system needs complex techniques because a drone beat frequency is highly dynamic and unpredictable. Therefore, the current static signal processing algorithms cannot show appropriate detection accuracy. With dynamic signal fluctuation and environmental clutters, it can fail to detect a drone or make false detection. It affects to the radar system integrity and safety. Constant false alarm rate (CFAR), one of famous static signal process algorithm is effective for static environment. But for drone detection, it shows low detection accuracy. In this paper, we suggest neural network based FMCW radar system for detecting a drone. We use recurrent neural network (RNN) because it is the effective neural network for signal processing. In our FMCW radar system, one transmitter emits FMCW signal and four-way fixed receivers detect reflected drone beat frequency. The coordinate of the drone can be calculated with four receivers information by triangulation. Therefore, RNN only learns and inferences reflected drone beat frequency. It helps higher learning and detection accuracy. With several drone flight experiments, RNN shows false detection rate and detection accuracy as 21.1% and 96.4%, respectively.

Keywords : FMCW radar, Neural network, Detection, Signal processing, Machine learning

1. 서 론

드론 (drone)으로 대표되는 소형 무인기 기술은 매우 빠르게 발전하고 있다. 군사, 산업, 여가 생활 전반에 걸쳐 드론은 새로운 기술로 인정받고 있다. 이와 함께 드론을 탐지하는 레이다 (radar) 시스템도 중요성이 증가하고 있으나, 현재의 레이다 시스템은 드론 탐지에 한계가 있다. 원인은 다음과 같다.

■ 드론 신호의 비정형성: 드론의 탐지 신호는 작은 환경 변화에도 크게 변화할 수 있으며, 클러터

(clutter)나 노이즈 (noise)와 같은 탐지 대상 외의 신호에 교란 및 증첩될 가능성이 매우 높다.

■ 드론 비행 환경의 특수성: 드론이 운용되는 낮은 고도에서의 다양한 대기 상태 변화와 지상의 클러터 및 노이즈는 기존의 레이다 시스템의 드론 탐지 시간 지연 및 성능 하락에 영향을 준다.

위와 같은 이유에서 기존의 레이다 시스템에서 사용하던 정적 탐지 기법은 드론을 탐지하는 데 효율적이지 못하다. 보편적으로 사용되는 CFAR (Constant False Alarm Rate) [1] 기법의 경우, 하한 (threshold) 이상의 신호 세기를 탐지된 것으로 인식한다. 때문에 클러터의 신호 세기가 기준 이상 이거나, 드론의 신호 세기가 기준 미달인 경우에 대하여 오탐지 (false detection)가 발생하게 된다.

본 논문에서는 인공 신경망 중 하나인 RNN (Recurrent Neural Network)을 사용하여 기존 레이다 시스템의 드론 탐지 문제를 해결하고자 한다. 드론 신호를 FMCW (Frequency Modulated Continuous Wave) 레이다를 이용하여 수집하고

*Corresponding Author (kims@kaist.ac.kr)

Received: Oct. 8 2018, Revised: Nov. 2 2018,

Accepted: Nov. 16 2018.

M. Jang, S. Kim: Korea Advanced Institute of Science and Technology

※ 본 연구는 국토교통부 '무인 비행체 안전 지원 기술 개발' 사업의 연구비 지원 (18ATRP-C108186-04)에 의해 수행되었습니다.

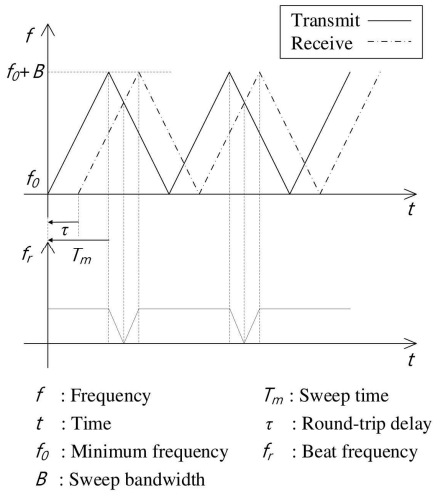


그림 1. FMCW 레이더 비트 주파수

Fig. 1 FMCW radar beat frequency

RNN에 학습시킴으로써, 드론 신호와 환경의 변화에 적응 가능한 탐지 기법을 제안한다.

레이더 시스템에 인공 신경망을 적용하고자 하는 연구는 많이 이루어져 왔으나, 실시간 탐지에 이용하는 데에는 부족하다. [2, 3]은 신호의 특징을 통하여 레이더의 종류를 판별하는 데에 그쳤으며, [4-6]은 근거리 탐지로 사용 범위가 제한되어 있다. 또한, 2차원상의 문제를 다루기 때문에 3차원 비행이 가능한 드론 탐지에 적용이 어렵다. 대부분의 관련 연구에서 처리 시간이 오래 걸리는 CNN (Convolutional Neural Network) [7]을 사용하였기 때문에 상대적으로 빠른 이동 속도를 가지는 드론의 실시간 탐지에 적용하는 것은 무리가 있다. [8]에서는 실제로 레이더 시스템에 인공 신경망을 적용하여 드론 탐지를 수행하였으나, GoogleNet [9]을 사용하여 추론 및 학습에 많은 시간이 필요하다는 단점을 가지고 있다. [12-14]는 RNN을 레이더 시스템에 적용한 최선의 연구들이다. [12]는 차량용 레이더 센서를 통해 주변 사물을 분류하기 위한 방법으로 RNN을 사용하였다. [13]은 도플러 레이더 (Doppler radar)에서 드론을 탐지하는 인공 신경망 중의 하나로 RNN을 사용하였으나, 결과적으로는 CNN을 통한 탐지율이 더 높다는 결과를 보이고 있다. [14]는 CNN과 RNN을 결합하여 레이더를 통한 지표면 상태 분석에 사용하였다.

본 논문에서 제안하는 인공 신경망 기반 드론 탐지 기법의 의의는 다음과 같다.

■ 기존의 레이더 시스템에서 사용하던 정적 탐지 기법을 인공 신경망을 사용하여 동적으로 변경함으로써, 신호 세기 변화율이 높은 드론에 적합한 새로운 탐지 기법을 제안하였다.

■ FMCW 레이더와 인공 신경망을 분석하여 신호 처리에 최적화된 RNN (Recurrent Neural Network) [10]을 사용함으로써, 학습 오류를 줄이고 드론 신호의 탐지율을 높였다.

본 논문의 이후 내용은 다음과 같다. 2장에서는 FMCW 레이더와 CFAR 기법을 설명하고 RNN의 구조를 분석한다. 3장에서는 본 논문의 제안 기법을 적용한 FMCW 레이더 시스템을 소개한다. 4장에서는 데이터 수집 및 학습 과정을 설명하고, 5장에서는 CFAR 기법과 제안 기법의 탐지율을 비교한다.

II. FMCW 레이더 및 RNN

이 장에서는 FMCW 레이더 및 현재 운용되고 있는 CFAR [1] 기법에 대하여 소개하고, 제안 기법의 핵심이 되는 RNN [10]에 대하여 설명한다.

1. FMCW 레이더

FMCW 레이더는 변조 주파수를 가지는 신호를 연속적으로 방사하여 물체를 탐지한다. 방사한 신호는 탐지 가능 거리 내의 물체에 닿으면 반사되어 돌아온다. 레이더는 계속해서 신호를 방사하고 있기 때문에, 현재 방사한 신호의 주파수와 반사되어 돌아온 신호의 주파수 사이에 시간 차이가 발생하게 된다. 이를 비트 주파수 (beat frequency)라고 한다. 그림 1은 비트 주파수 그래프이다.

물체에서 반사된 비트 주파수를 측정하면 물체와 FMCW 레이더 수신기 (receiver)간의 거리를 계산할 수 있다. 비트 주파수를 이용한 거리 계산 공식은 다음과 같다.

$$R = \frac{f_r \times c \times T_m}{2B} \quad (1)$$

식 (1)에서 R은 탐지한 수신기와 탐지된 물체 간의 거리, f_r 은 탐지된 비트 주파수를 의미한다. B와 T_m 은 각각 변조 주파수 대역과 변조 주기이다 (그림 1). 마지막으로 c는 광속이다. 변조 주파수 대역 및 주기는 사전에 결정되는 값이며, 광속은 물리 상수이다. 따라서 물체의 비트 주파수로 물체와 수신기 간의 거리를 계산할 수 있다.

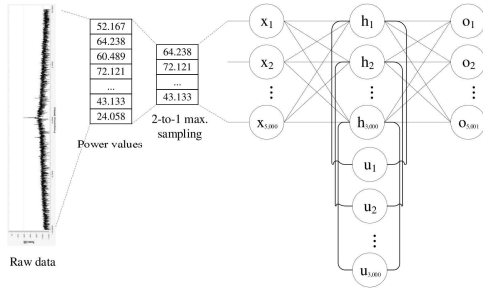


그림 2. RNN 학습 및 추론 과정
Fig. 2 RNN learning and inferring process

2. CFAR 기법

CFAR (Constant False Alarm Rate) [1] 기법은 현재 레이더 시스템에서 사용되고 있는 정적 신호 처리 기법의 하나다. 탐지로 인식하기 위한 신호 세기의 하한을 설정해 두고, 이 세기를 초과하는 신호가 탐지되면 물체가 있는 것으로 판단한다.

CFAR 기법은 FMCW 레이더 시스템에도 적용될 수 있다. 측정된 비트 주파수 세기의 하한을 설정하고, 이 이상의 세기를 가지는 비트 주파수가 수신되면 물체를 탐지한 것으로 정의한다. 하지만 드론의 경우에는 비트 주파수 세기 하한선을 고정적으로 결정할 수 없다. 드론의 다양한 모양과 크기, 변칙적이고 빠른 움직임 때문에 비트 주파수의 세기가 지속적으로 변화하기 때문이다. 이 때문에 하한 이하의 드론 비트 주파수 세기에 대하여 탐지에 실패하는 문제가 발생한다. 나아가 드론의 저고도 비행으로 인하여 건물, 나무 등과 같은 주변의 다양한 환경적 요인들이 신호를 반사하고 클러터와 노이즈로써 비트 주파수를 발생시킨다. 클러터와 노이즈에 대한 비트 주파수 세기는 하한 이상이 될 수 있으며, 오탐지를 발생시키는 요인이 된다.

3. RNN

RNN (Recurrent Neural Network) [10]은 인공 신경망 중 하나으로써, 은닉층 (hidden layer)을 구성하는 회귀 뉴런 (recurrent neuron)이 있어 신호 처리에 강한 특성을 가진다. RNN의 회귀 뉴런은 추론 단계마다 이전의 추론 결과를 다시 입력으로 사용한다 (그림 2). 이 때문에 이전의 추론에 근거한 결과를 도출할 수 있다. FMCW 레이더 신호는 연속적인 비트 주파수 흐름 (beat frequency stream)을 발생시키기 때문에 RNN의 특성이 적용될 수 있다. 드론의 이동도 연속적이기 때문에, 탐

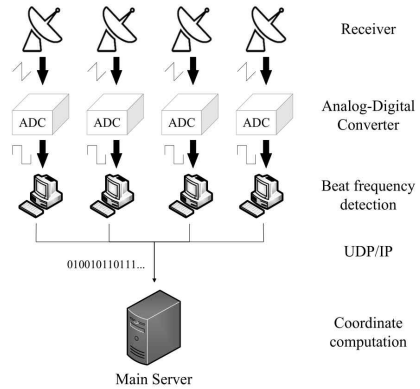


그림 3. 시스템 하드웨어 구성
Fig. 3 System hardware

색 시간에 따른 동적인 신호 처리가 필요하다. 이를 RNN을 통하여 학습하고 처리할 수 있다.

연속적인 시간에서의 비트 주파수 흐름의 세기를 RNN에 입력하여 특정 시간에서의 비트 주파수 흐름을 학습한다. 단편적인 비트 주파수 흐름에 대하여 리키지 (leakage), 클러터 (clutter)와 노이즈 (noise), 드론의 비트 주파수를 학습한다. 연속적인 비트 주파수 흐름에 대해서는 변화하는 드론의 비트 주파수 패턴을 학습한다. 학습이 완료된 RNN을 FMCW 레이더 시스템의 탐지 기법으로 사용하여 드론의 탐지율을 향상 시킬 수 있다.

III. 인공 신경망 기반 FMCW 레이더 시스템

본 논문에서 제안하는 레이더 시스템은 FMCW 레이더를 포함하는 하드웨어와 비트 주파수 처리를 위한 소프트웨어로 구분된다.

1. 하드웨어

그림 3은 인공 신경망 기반 FMCW 레이더 시스템의 하드웨어 구성이다. 본 논문에서는 1개의 송신기 (transmitter)와 4개의 수신기 (receiver)를 사용한다. 송신기에서는 사전에 지정된 주파수 대역으로 신호를 연속적으로 방출하며, 수신기는 송신기가 방출한 신호를 지속적으로 수신한다.

각 수신기는 유선으로 연결된 소형 컴퓨터를 가지고 있다. 이 소형 컴퓨터에서 학습이 완료된 RNN을 이용하여 드론의 비트 주파수를 추론한다. RNN을 통해 얻은 드론의 비트 주파수는 메인 서버에 UDP 통신을 통하여 전송된다. 메인 서버에서는

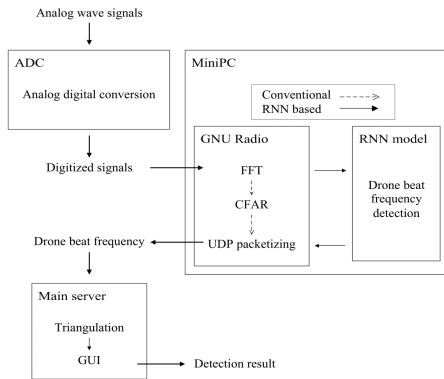


그림 4. 비트 주파수 탐지 과정

Fig. 4 Beat frequency detection process

복수 개의 수신기가 보내온 드론 비트 주파수로 드론의 좌표와 위치를 계산한다. 이 과정에서 각 소형 컴퓨터와 메인 서버는 드론의 실시간 탐지를 위하여 적절한 스케줄링 (scheduling) 기법을 사용하여야 한다 [15, 16].

RNN을 통한 드론 비트 주파수의 추론과 이후의 좌표 계산 과정을 서로 다른 장치에 분할하여 처리함으로써, 메인 서버에 집중될 수 있는 연산 부하를 줄인다. RNN은 사전에 학습이 완료된 상태로 학습을 위한 하드웨어 자원과 시간이 필요하지 않아 소형 컴퓨터에서도 운용할 수 있다.

2. 소프트웨어

드론 비트 주파수의 탐지 과정은 그림 4와 같다. 본 논문에서는 RNN을 기반으로 드론 비트 주파수를 추론하는 수신기 내부 처리 과정만을 설명한다.

아날로그 (analog) 형태로 수신된 신호는 아날로그-디지털 변환 회로 (Analog Digital Converter, ADC)를 사용하여 일정 샘플링 속도 (sampling rate)로 디지털 (digital)화된다. 디지털 신호 데이터를 고속 푸리에 변환 (Fast Fourier Transform, FFT)을 통하여 비트 주파수 흐름으로 변환한다. 비트 주파수 흐름을 RNN에 입력하여 드론 비트 주파수를 추론한다. 추론된 드론 비트 주파수는 UDP 통신을 이용하여 메인 서버에 전송한다.

기존에 수행하던 정적 탐지 방식은 RNN 대신에 CFAR 기법을 사용한다. 소프트웨어 처리 과정 전체를 수정하지 않고 드론 비트 주파수 탐지 과정만을 변경한다. 처리 과정 외적으로는 입력하는 아날로그 신호와 출력되는 드론 비트 주파수에 변화가 없다. 따라서 추가적인 비용이 소모되지 않는다. 하

드웨어도 변경되지 않으므로, 기존 레이다 시스템에서 탐지 기법의 변환이 쉽고 운용이 편리하다.

IV. 실험 환경

제안 기법의 드론 탐지율을 확인하기 위하여 다음과 같은 실험 환경을 구현하였다.

1. FMCW 레이다 및 수신 주파수 처리

표 1은 실험에 사용한 FMCW 레이다의 제원이다. FMCW 레이다 송신기 1대와 수신기 4대를 사용하였으며, 수신기는 송신기로부터 약 30m 이격시켜 네 방향에 위치시켰다.

4대의 수신기가 수신한 신호는 GNU Radio를 이용하여 처리하였다. 비트 주파수 흐름은 변조 주기마다 10,000개의 배정도형 (floating point) 데이터로 전환되어 RNN의 입력으로 사용되었다. 그림 5는 GNU Radio에서 FFT를 수행하여 나온 비트 주파수 흐름의 일부이다.

2. RNN 및 학습 환경

드론 비트 주파수 탐지를 위한 RNN은 그림 2와 같다. FFT를 통해 얻은 비트 주파수 흐름은 각 비트 주파수의 세기를 데시벨 (decibel) 값으로 가진다. 하나의 비트 주파수 흐름에는 10,000개의 비트 주파수가 존재한다. 하지만, 10,000개의 배정도형 데이터는 RNN의 학습 및 추론 시간을 증가시키고 학습률도 낮추는 원인이 된다. 이와 같은 이유에서 이웃하는 두 비트 주파수 세기에서 큰 값을 선택하는 2-to-1 max. 샘플링을 이용하여 데이터를 5,000개로 압축하였다. 식 (1)에 표 1의 제원을 대입하면 연속된 두 비트 주파수 사이에는 약 2kHz의 차이가 있음을 알 수 있으며, 이는 약 1m 정도의 거리 차이이다. 표 2의 드론 사양에 비하여 작은 수치이기 때문에 오차가 크지 않다고 판단하였다.

입력층 (input layer)의 뉴런 개수는 5,000개이다. 은닉층의 뉴런 개수는 3,000개로서, 입력층의 크기보다 작다. 이와 같은 구성을 통하여 데이터의 크기와 데이터 간의 독립성을 줄일 수 있다. 출력층 (output layer)의 뉴런 개수는 5,001개이며, 원-핫 벡터 (one-hot vector)로 표현된다. 원-핫 벡터는 인공 신경망의 출력으로 자주 사용되는 데이터 형식이므로써, 해당하는 위치의 데이터만 '1'의 값을 가지고 나머지는 모두 '0'의 값을 가진다. 본 논문의 기법에서는 드론 비트 주파수에 해당하는 데이터




그림 5. 비트 주파수 흐름
Fig. 5 Beat frequency stream

표 1. FMCW 레이다 제원
Table 1. FMCW radar parameters

Parameter	Value
Sweep bandwidth	150MHz
Carrier frequency	14.105GHz
Modulation scheme	Chirp
Waveform	sawtooth
PRI	500 μ s
Modulation frequency	2kHz
ADC sampling rate	20MHz
Detectable range	About radius 1km

표 2. 드론 사양
Table 2. Drone specifications

Item	Specification
Model name	DJI Inspire1 T600
Weight (with battery)	2935g
Max. ascending speed	5m/s
Max. descending speed	4m/s
Size	438*451*301mm ³

위치가 '1'로 출력된다. 드론이 탐지되지 않으면 5,001번째 데이터가 '1'을 출력하게 된다.

RNN의 학습에는 NVIDIA GeForce 1050 Ti GPU에 CUDA 라이브러리 (library)와 Tensorflow를 사용하였다.

3. 실험 데이터의 수집

RNN과 CFAR 기법의 비교를 위하여 드론을 비행 시나리오 (scenario)를 바탕으로 비행하여 데이터를 수집하였다. 표 3은 드론 비행 시나리오이다. 시나리오는 드론이 없는 시나리오와 세 가지의 비행 상태에 대한 시나리오로 구성된다. 시나리오별로 ADC 샘플링 기준, 약 2GB의 데이터를 수집하였다. 데이터 수집 중에 CFAR 기법을 이용하여 탐지를 수행하였으며, RNN 학습 이후에 학습에 사용되지 않은 데이터로 추론을 수행하였다.

CFAR 기법의 비트 주파수 세기 하한은 드론이 없는 환경의 데이터를 이용하여 결정하였다. 드론이 없는 환경에서 비트 주파수 흐름의 세기를 일정 시간 동안 기록한 뒤, 그 중에서 리키지 (leakage)를 제외한 가장 높은 세기를 하한으로 설정하였다.

표 3. 드론 비행 시나리오
Table 3. Drone flight scenario

Scenario	Case	Drone flight	Data usage
1	1,2	Drone-free	Analysis
	3		Learning
2	-	300m vertical takeoff	Learning
3	-	300m vertical descent	Analysis
4	-	150m horizontal movement	Analysis

RNN은 드론이 있는 데이터로는 시나리오 2의 데이터만 학습하였으며, 시나리오 3과 4의 데이터를 사용하여 추론을 수행하였다. 드론이 없는 경우에는 세 가지 케이스 (case)의 서로 다른 환경을 조성하여, 케이스 3의 데이터를 RNN의 학습 및 CFAR 기법의 비트 주파수 하한 설정에, 1과 2의 데이터를 결과 분석에 이용하였다. 모든 학습은 정확도가 90% 이상이 될 때까지 수행하였으며, 학습에 사용된 데이터는 결과 분석에서 제외하였다.




그림 6. CFAR 기법과 RNN의 오탐지 발생률 (좌) 및 탐지율 (우)

Fig. 6 False detection rate (Left) and detection accuracy (Right) of CFAR algorithm and RNN

V. 실험 결과

그림 6은 CFAR 기법과 RNN의 오탐지 발생률 및 탐지율을 비교한 결과이다. 오탐지 발생률 (좌)은 드론이 없는 환경에서 드론이 있다고 탐지할 확률이다. 케이스 1과 2 모두에 대하여 RNN 기반의 탐지 기법이 더 낮은 오탐지 발생률을 보였다 (케이스 1: 48.9%, 케이스 2: 6.7%). 또한, 두 케이스 간의 변화량도 RNN이 더 작다 (CFAR 기법 49.7%, RNN 7.5%). 이는 다양한 환경 변화에 대해서 RNN의 적응성이 상대적으로 더 높음을 의미한다. 케이스 1에서 CFAR 기법의 오탐지 발생률이 RNN보다 매우 높는데, 클러터 및 노이즈로 인하여 하한선 이상의 세기를 가지는 비트 주파수가 많이 발생하였다고 유추할 수 있다. RNN의 경우에는 환경적인 요인에 의하여 다른 비트 주파수의 세기가 높아져도 이를 드론 비트 주파수로 인식하는 오류를 발생시키지 않았다. CFAR 기법이 24%의 오탐지 발생률을 보이는 케이스 2에서도 RNN은 더 낮은 17.3%의 오탐지 발생률을 보임으로써 CFAR 기법을 대체하여 사용할 수 있음을 확인하였다.

탐지율 (우)은 드론이 있는 시나리오 3과 4에 대하여 비교 분석하였다. 두 시나리오 모두에서 RNN이 CFAR 기법보다 높은 탐지율을 보였다 (시나리오 3: 32.9%, 시나리오 4: 32.3%). CFAR 기법의 경우에는 평균 63.8%의 탐지율을 보였는데, 이는 드론 비트 주파수의 세기가 하한 이하일 확률이 약 40% 정도로 높다고 해석할 수 있다. RNN의 경우에는 드론 비트 주파수의 세기가 낮은 경우에도 탐지를 원활히 수행하여 평균 96.4%의 탐지율을 나타내었다. 높은 탐지율에 대한 주된 원인은 리

키지, 클러터 및 노이즈 문제에 대한 RNN의 학습에 있다. CFAR 기법의 경우, 리키지 제거를 위하여 리키지 주변의 일정 비트 주파수를 탐지 대상에서 제외하기 때문에 이 영역 내에 드론 비트 주파수가 발생하면 탐지할 수 없다. 하지만, RNN의 경우에는 리키지가 가장 높은 세기를 가지는 비트 주파수임을 학습함으로써, 가령 비트 주파수가 이동하거나 드론 비트 주파수와 가까워도 이를 분류할 수 있다. 클러터의 경우에는 지속적으로 동일한 비트 주파수에 발생하는 경우가 많기 때문에 클러터 비트 주파수를 학습하여 이를 드론 비트 주파수로 오인하지 않는다. 특히, 노이즈는 모든 비트 주파수의 세기가 증폭되는 플럭추에이션 (fluctuation)을 짧은 시간에 무작위로 발생시킬 수 있다. 플럭추에이션이 발생하면 드론 비트 주파수의 세기가 주변의 노이즈보다 낮아져서 CFAR 기법은 탐지가 불가능하게 된다. 이 경우에도 RNN은 이전의 데이터를 바탕으로 현재의 데이터를 보정함으로써 플럭추에이션을 무시하고 드론은 추론해 낼 수 있다.

VI. 결론

본 논문에서는 인공 신경망 기반 FMCW 레이다 시스템을 제안하였다. 기존의 정적 탐지 기법은 드론과 같은 소형 무인기에 대해서 상대적으로 낮은 탐지율을 보인다. 이를 해결하기 위하여 RNN을 탐지 기법으로 사용하였다. 기존의 탐지 기법과 입력 데이터 형식이 완전히 일치하며, 하드웨어적인 개선 기법이 아니기 때문에 적용 가능성이 높고 운용이 편리하다. 네 가지 시나리오 기반의 탐지율 비교 실험에서 본 논문의 제안 기법은 평균 오탐지 발생률

21.1%, 드론 탐지율 96.4%로 기존의 CFAR 탐지 기법보다 높은 정확도를 나타내었다. 향후 연구 과제로서 추론 시간 감소를 위한 인공 신경망의 개선이나 복잡한 드론 비행에 대하여 추적 및 탐지율을 높이는 등의 연구가 가능할 것으로 기대된다.

References

- [1] H. Rohling, "Radar CFAR Thresholding in Clutter and Multiple Target Situations," *Proceedings of IEEE Transactions on Aerospace and Electronic Systems*, Vol. AES-19, No. 4, pp. 608-621, 1983.
- [2] C. Jeong, Y. Jung, S. Lee, "Neural Network-based Radar Signal Classification System Using Probability Moment and ApEn," *Journal of Soft Computing*, Vol. 22, No. 13, pp. 4205-4219, 2018.
- [3] M. Jan, "Radar Signal Identification Using a Neural Network and Pattern Recognition Methods," *Proceedings of IEEE Telecommunications and Computer Engineering*, pp. 79-83, 2018.
- [4] J.M. García, D. Zoeke, M. Vossiek, "MIMO-FMCW Radar-Based Parking Monitoring Application With a Modified Convolutional Neural Network With Spatial Priors," *Proceedings of IEEE Access*, Vol. 6, pp.41391-41398, 2018.
- [5] R. Pérez, F. Schubert, R. Rasshofer, E. Biebl, "Single-Frame Vulnerable Road Users Classification with a 77 GHz FMCW Radar Sensor and a Convolutional Neural Network," *Proceedings of IEEE International Radar Symposium*, pp. 1-10, 2018.
- [6] B. Vandersmissen, N. Knudde, A. Jalavand, I. Couckuyt, A. Bourdoux, "Indoor Person Identification Using a Low-Power FMCW Radar," *Proceedings of IEEE Transactions on Geoscience and Remote Sensing*, Vol. 99, pp. 1-12, 2018.
- [7] A. Krizhevsky, I. Sutskever, G.E. Hinton, "Imagenet Classification with Deep Convolutional Neural Networks," *Proceedings of Advances in neural information processing systems*, pp. 1097-1105, 2012.
- [8] B. Kim, "(A) Study on Radar for Micro-drone Detection and Target Classification Based on Deep Learning," Ph.D. Dissertation, 2017.
- [9] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, A. Rabinovich, "Going Deeper with Convolutions," *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1-9, 2015.
- [10] E.D. Solovyeva, "Types of Recurrent Neural Networks for Nonlinear Dynamic System Modeling," *SCM, 2017 XX IEEE International Conference*, pp. 252-255, 2017.
- [11] M. Kang, M. Lee, S. Kim, "Leakage and Clutter Suppression on FMCW Radar System for Small Unmanned Aerial Vehicle Detection," *Proceedings of 2017 Defense SW/ICT Convergence Conference, SIGDS, 2017. (in Korean)*
- [12] C. Grimm, T. Breddermann, R. Farhoud, T. Fei, E. Warsitz, R. Haeb-Umbach, "Discrimination of Stationary from Moving Targets with Recurrent Neural Networks in Automotive Radar," *Proceedings of IEEE MTT-S International Conference*, pp. 1-4, 2018.
- [13] D.A. Brooks, O. Schwander, F. Barbaresco, J.Y. Schneider, M. Cord, "Temporal Deep Learning for Drone Micro-Doppler Classification," *Proceedings of IEEE International Radar Symposium*, pp. 1-10 2018.
- [14] M. Xu, C. Fan, J.D. Paden, G.C. Fox, D.J. Crandall, "Multi-Task Spatiotemporal Neural Networks for Structured Surface Reconstruction," *arXiv, 1801.03986*, 2018.
- [15] M. Lee, S. Kim, "Performance Controllable Shared Cache Architecture for Multi-Core Soft Real-Time Systems," *Proceedings of IEEE Computer Design*, pp. 519-522, 2013.
- [16] T. Park, S. Kim, "Dynamic Scheduling Algorithm and Its Schedulability Analysis for Certifiable Dual-criticality Systems," *Proceedings of Embedded Software*, pp. 253-262, 2011.

Myeongjae Jang (장 명 재)

He is currently pursuing the M.S. degree from with the School of Computing from Korea Advanced Institute of Science and Technology.

Email: myeongjae0409@kaist.ac.kr

Soontae Kim (김 순 태)

He is received the Ph.D. degree from Pennsylvania State University, State College, PA, USA. He has been with the School of Computing,

Korea Advanced Institute of Science and Technology, Daejeon, South Korea, as an Associate Professor.

Email: kims@kaist.ac.kr