

드론 탐지 및 분류를 위한 레이더 영상 기계학습 활용

문민정¹ · 이우경^{2*}

Machine learning based radar imaging algorithm for drone detection and classification

Min-Jung Moon¹ · Woo-Kyung Lee^{2*}

¹Graduate student, Department of Electronic Engineering, Korea Aerospace University, Gyeonggi-do, 10540 Korea

^{2*}Professor, Department of Electronic Engineering, Korea Aerospace University, Gyeonggi-do, 10540 Korea

요약

최근 드론은 가격 하락, 소형화와 함께 높은 기술 발전에 힘입어 드론 보급이 민군에 걸쳐 증가하면서 보안안전사고, 치안·안보 위협 등의 문제를 유발할 가능성도 커지고 있다. 드론으로 인해 발생하는 사건 및 사고를 예방하기 위해서는 드론의 출현에 대응할 수 있는 탐지 기술이 우선적으로 선행되어야 한다. 드론은 크기가 작고 전파 반사도가 낮은 재질로 구성되어 있어 음향, 적외선, 레이더의 운용만으로는 탐지가 어렵다. 최근 영상 식별 성능을 강화하기 위해 레이더 신호에 인공지능을 접목한 연구사례가 증가하는 추세이다. 본 논문에서는 레이더 영상을 이용한 드론 탐지 기술을 소개하며, 드론의 모의실험 데이터와 실제 실험 데이터를 기반으로 인공지능 기술에 적용하여 드론의 분류 정확도를 효과적으로 입증하였다.

ABSTRACT

Recent advance in low cost and light-weight drones has extended their application areas in both military and private sectors. Accordingly surveillance program against unfriendly drones has become an important issue. Drone detection and classification technique has long been emphasized in order to prevent attacks or accidents by commercial drones in urban areas. Most commercial drones have small sizes and low reflection and hence typical sensors that use acoustic, infrared, or radar signals exhibit limited performances. Recently, artificial intelligence algorithm has been actively exploited to enhance radar image identification performance. In this paper, we adopt machined learning algorithm for high resolution radar imaging in drone detection and classification applications. For this purpose, simulation is carried out against commercial drone models and compared with experimental data obtained through high resolution radar field test.

키워드: 레이더, ISAR, 마이크로 도플러, 기계학습, CNN

Keywords: Radar, ISAR, Micro-doppler, Machine learning, CNN

Received 6 January 2021, Revised 11 January 2021, Accepted 17 April 2021

* Corresponding Author Woo-Kyung Lee(E-mail:wklee@kau.ac.kr Tel:+82-2-300-0319)

Professor, Department of Electronic Engineering, Korea Aerospace University, Gyeonggi-do, 10540 Korea

Open Access <http://doi.org/10.6109/jkiice.2021.25.5.619>

print ISSN: 2234-4772 online ISSN: 2288-4165

©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.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서론

드론은 크기가 작고 전파 반사도가 낮은 재질로 구성되어 기존의 레이더 운용으로는 탐지가 어렵다. 레이더 신호는 잡음과 신호 세기의 영향을 크게 받기 때문에 도심과 같은 실제 비행 환경에서 드론을 탐지하기 위해서는 추가적인 신호처리가 필요하다[1-4]. 기존 레이더를 활용하여 드론을 탐지하는 연구는 단순히 드론의 존재 여부를 판별하는 드론 탐지를 다루고 있으나 이는 표적의 형상 정보가 누락되어 오탐 가능성이 높다. 최근 드론에 대한 레이더 탐지 연구 동향을 보면 로터에서 반사되는 신호의 도플러 정보를 인식하여 식별하는 기술 적용이 활발하다[5-6].

드론 로터에 의해 발생하는 마이크로 도플러 현상은 로터의 수나, 재질, 크기, 비행경로 등 다양한 요인에 의해 변하게 되며, 외부 환경적인 요소에도 영향을 많이 받는다. 따라서 그 결과가 유동적이며 정량화된 분석이 어렵다. 이에 대한 대응으로 최근 연구는 마이크로 도플러 특징점을 정확히 추출한 후 기계학습 기반의 데이터 분석을 적용하는 방법이 증가하는 동향을 보인다[7-10]. 그림 1은 마이크로 도플러 특성과 기계학습의 모식도를 보인다.

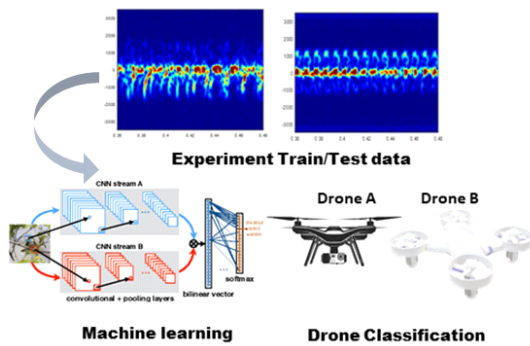


Fig. 1 Micro doppler characteristics and Machine Learning Schematic

시뮬레이션에서 추출되는 드론 반사파의 마이크로 도플러 특성은 표적의 종류에 따라 서로 구분하는 것이 가능하나 실제 이동하는 드론에 대한 실험에서 이론과 동일한 결과를 얻는 것은 매우 어렵다. 레이더 송신기와 드론의 상호 기하학적 위치 또는 드론의 이동 속도에 따라 수신단에서의 마이크로 도플러 특성은 큰 편차를 보

여 드론 탐지 및 분류 오차가 크게 증가한다. 따라서 정확한 드론의 인식 및 분류를 위해서는 드론의 구조를 파악할 수 있는 추가적인 영상 정보의 획득이 필수적이다.

ISAR(Inverse Synthetic Aperture Radar) 기술은 표적에서 반사되는 신호를 일정 시간 동안 누적하여 저장한 후 이를 각각 거리 및 방위 방향으로 고해상도 정보 처리를 추출하여 2차원 영상을 생성한다. 표적의 이동이 단순한 직선일 경우 레이더 신호의 대역폭에 비례하여 해상도를 개선할 수 있으나 드론처럼 반사도가 낮고 이동이 불규칙한 시나리오에서는 고품질 영상 획득이 매우 어렵다. 따라서 일반적인 ISAR기법은 비교적 일정한 비행경로를 갖는 표적의 식별에 활용된다. 실제 비행하는 드론에서는 이동 궤적에 따른 오류가 증가하여 해상도가 낮아지거나, 선명도가 떨어져 영상 분류 정확도에서 오류가 증가한다.

최근에는 영상 식별 성능을 강화하기 위해 레이더 신호에 딥러닝과 같은 인공지능 알고리즘을 도입하는 노력이 시도되고 있으나, 레이더 실험을 통한 영상 획득에는 많은 시간 소요가 필요하므로 기계 학습에 필요한 충분한 데이터를 확보하기 어렵다. 기존의 마이크로 도플러 기반 분류 기법은 실내에 환경의 근거리 실험을 통해 학습 데이터를 확보할 수 있으나 ISAR 학습 영상은 원거리에서 실제 이동하는 드론에서 추출되어야 하므로 가용 데이터가 제한된다. 이는 ISAR 영상의 기계학습 활용에서 가장 큰 장벽이 되어 관련 연구가 활발하지 못하게 되는 이유가 된다.

본 연구에서는 기존 레이더 기반 드론 탐지 기법에서 주로 사용되는 마이크로 도플러 분석을 확장하여 ISAR 영상 데이터를 기계학습에 활용할 수 있는 가능성을 제시한다. 드론에서 반사된 신호로부터 마이크로 도플러 특성과 ISAR 영상을 각각 추출하고 각각 기계학습을 적용하여 서로 다른 드론의 형상을 분석하고 분류하는 기법을 제시한다. 기계 학습에 소요되는 데이터 생성을 위해, 실험적으로 확보한 ISAR 영상을 기반으로 다양한 드론 궤적 시나리오에 대한 학습 데이터 영상을 모의 실험으로 재생산하여 기계학습에 활용한다. 이를 서로 다른 복수의 드론에 대해 적용하여 분류를 수행한 후 기존의 마이크로 도플러 신호 기반으로 수행한 분류 결과와 비교한다.

II. 드론 표적에 대한 레이더 반사파 수집

2.1. 마이크로 도플러 기반 탐지

도플러 효과는 산란체와 관측자의 상대속도에 따른 진동수와 파장의 변화 현상으로 비선형의 경로를 비행하는 표적의 진동, 회전, 가속과 같은 작은 움직임에 의해 고유의 특성으로 관측된다. 따라서 서로 다른 로터 구조를 갖는 드론 표적의 인식 및 식별에 활용된다[4-7]. 마이크로 도플러 분석 기법은 비교적 간단한 구조의 CW(Continuous Wave) 레이더를 이용하여 낮은 비용의 탐지 체계를 구축할 수 있으나 제한된 출력으로 인해 주로 근거리에서 운용된다. 이동하는 드론의 로터에서 생성된 고유 진동 특성에 의해 구분되는 마이크로 도플러 패턴을 파악하여 표적 드론의 크기와 구조 특성을 유추하게 된다.




Fig. 2 Drone Micro Doppler Detection Geometry

이동하는 드론의 마이크로 도플러 특성을 분석하기 위해 가정한 기하구조는 그림 2와 같다. 송출된 전파가 드론에서 반사될 때 각 로터에서 산란이 발생한다. 산란 파 변형은 로터의 길이, 회전수, 레이더와의 사잇각에 의해 결정된다.

표적의 도플러 특성을 유발하는 산란점의 위치를 P라고 한다면 P점에서의 위상값 $\Phi(t)$ 은 다음과 같이 표현할 수 있다. k, c, f 는 각각 파수, 빛의 속도, 중심주파수를 나타낸다.

$$\Phi(t) = -2k \cdot r(t) = -2\pi f \frac{2r(t)}{c}, k = \frac{2\pi}{\lambda} \quad (1)$$

$r(t)$ 는 레이더와 P의 거리를 나타낸다. 표적의 회전과 진동에 의해 발생하는 도플러 천이 주파수는 위상값 $\Phi(t)$ 을 미분한 주파수 f_D 와 같다. 여기서 v_t 는 드론의 속도 a_t 는 가속도이다. w_r 과 α_r 은 로터의 각속도와 각가속도를 의미한다.

$$\begin{aligned} f_D &= \frac{1}{2\pi} \frac{\partial}{\partial t} \Phi(t) = -\frac{2f}{c} \frac{\partial}{\partial t} r(t) \\ &= -\frac{2f}{c} (v_t + a_t t + \dots) \\ &\quad + \frac{2f}{c} (w_r + \alpha_r t + \dots) \\ &\quad \times (x \cdot \sin \varnothing(t) + y \cdot \cos \varnothing(t)) \end{aligned} \quad (2)$$

식 (2)에 의해 발생된 주파수 편이는 드론 반사파에 실려 레이더 수신단에서 검출된다. 실제로는 드론의 이동에 따라 도플러 정보는 불규칙한 패턴을 보이고 각 로터의 회전 수가 달라져 도플러 대역폭이 증가하는 효과도 발생한다. 동일한 드론에서도 관측 순간마다 다른 반사 특성을 보이게 되어 실제로는 드론이 검출되어도 드론 특성에 따른 분류는 어렵거나 불가능한 경우도 발생한다.

2.2. ISAR 영상 기반 탐지

도플러 분류 기반의 드론 탐지 기술은 적용 거리가 제한되어 실용성이 낮아 주로 근거리 표적에 대한 정보에 활용된다. 이를 보완하기 위해 최근에는 드론의 단순 탐지에서 나아가 정밀 형상을 획득할 수 있는 고정밀 레이더 영상 식별 기술이 제안되고 있다. ISAR 영상은 움직이는 물체에 대해 높은 해상도를 갖는 전천후 영상을 제공하는데 지상의 고정 레이더를 사용하여 항공기 또는 드론을 정보를 확보한다. 그림 3은 드론 ISAR의 기하구조를 보인다.




Fig. 3 Drone ISAR geometry

고품질 ISAR 영상이 확보되면 비교적 먼 거리에서 드론의 탐지 및 식별까지도 가능하다. 일반적으로 항공기나 미사일 등의 비행체는 적은 요동의 직선 비행을 하지만 드론의 경우 가벼운 중량으로 바람의 영향을 상대적으로 크게 받고, 심한 요동이 발생하여 ISAR 영상 품질이 저하된다.

드론의 비행으로 발생하는 요동은 관측 거리의 변화 $\Delta R(t)$ 에 의해 주로 발생한다. 이때 레이더 관측점으로부터 드론까지의 거리 R 은 다음과 같다.

$$R(t) = \Delta R(t) + \sqrt{R_0^2 + (V_r t)^2} \quad (3)$$

영상처리에 앞서 발생한 요동 $\Delta R(t)$ 이 RCMC (Range Cell Migration Error)가 발생하지 않을 정도로 충분히 작다고 가정하면, 테일러 전개를 이용하여 아래와 같이 $R(t)$ 를 2차 다항식으로 전개할 수 있다. $\lambda, \Delta\phi$ 는 각각 파장과 위상 변화율을 의미한다.

$$R(t) = R(t_0) + \left\{ \frac{d\Delta R(t_0)}{dt} - V_r \sin\theta(t_0) \right\} (t - t_0) + \left\{ \frac{d^2\Delta R(t_0)}{dt^2} + \frac{V_r^2 \cos^2\theta(t_0)}{2R(t_0)} \right\} (t - t_0)^2 + \dots$$

$$\Delta R(t) = \sum_{n=3}^{N+1} a_n t^n$$

$$\Delta\phi = \exp \left[+ \frac{4\pi \cdot \Delta R(t)}{\lambda} \right]$$

$\Delta R(t)$ 의 크기를 작다고 가정하였으나, 드론의 요동이 커져 $\Delta R(t)$ 가 증가하면 영상의 품질이 저하되어 드론 식별이 어렵다. 따라서 드론의 요동에 대한 보상이 필요하나, 이동하는 표적 드론에 대한 정확한 궤적 정보는 확보할 수 없으므로 불가피하게 오차가 발생하고 이는 ISAR 영상 품질 저하로 이어진다. 따라서 고품질의 ISAR 영상을 육안으로 확인하여 분류하는 것은 매우 어려운 과정이 된다. 동일한 드론에 대해서도 이동 궤적에 따라 다른 형태의 ISAR 형상이 얻어지므로 일반적인 방식으로는 식별이나 분류 정확도를 보장할 수 없다.

따라서 마이크로 도플러 정보를 통한 드론 탐지와 유사하게 ISAR 영상을 통한 드론 식별 역시 기계 학습의 도입이 매우 유용할 것임을 추론할 수 있다. 이를 위해 학습 데이터를 생성하는 것이 필요한데, 마이크로 도플러 신호와는 달리 ISAR는 모의 실험 과정에서 드론의 구조 정보 외에 이동 궤적 정보가 필요하여 실제 환경을 모사하는 표적 생성이 어렵다. 본 연구에서는 실제 실험을 통해 획득한 드론 ISAR 정보를 학습 데이터 생성에 활용하였다.

III. 실험 데이터 기반 기계 학습 적용

드론에 대한 레이더 반사파 정보를 실험적으로 확보하기 위해 C-대역 FMCW 레이더를 적용하여 신호를 수집하였다. 표적이 되는 실험 드론은 쿼드콥터인 DJI 팬텀-3와 헬리콥터인 MC-5를 활용하였다. 각각의 드론은 표 1과 같이 로터의 구성이 상이하고 구조체의 크기도 서로 다르다. 마이크로 도플러 신호는 로터에 의해 결정되는 반면 ISAR 영상은 드론 본체의 형상에 의해 결정된다.

실험 환경은 그림 4와 같다. C-대역의 고정된 레이더에 수직 방향으로 직선 비행하는 드론에 대해 레이더 신호를 수집하였고 동일한 실험에서 각각 마이크로 도플러와 ISAR 영상 정보를 생성하였다.



Fig. 4 Doppler detection experiment using C-band radar

3.1. 마이크로 도플러 탐지 실험

수신 신호에서 마이크로 도플러 정보를 추출하기 위해서는 신호 수집 구간이 충분히 길어야 하지만 드론은 불규칙하게 이동하므로 실제 수집할 수 있는 구간은 제한된다. 본 실험에서 수신 신호의 수집 시간은 3초로 제한되었다.

수신 신호는 회전하는 로터로부터의 레이더 반사 신호를 STFT(Short Time Fourier Transform)으로 분석하였다. CW 레이더 수신단에서 검출되는 도플러 정보들은 이러한 요소들이 반영되어 나타나며, 스펙트로그램과 캡스트로그램 등의 신호처리를 통해 도플러 신호를 다양하게 분석할 수 있다. 다음 표 1은 실험에 활용한 드론 팬텀-3와 MC-5의 사양을 보인다.

Table. 1 Test drone systems

DJJI PH3			
Weight	1.280 kg	Type	Quad Type
Speed	5.5 m/s	Size	0.3*0.3*0.2

MC-5			
Weight	9.8 kg	Type	Hexa Type
Speed	6.0 m/s	Size	1.2*0.1.2*0.8

그림 5(a),(b)는 각각 팬텀-3와 MC-5 드론에서 획득한 스펙트로그램이며 각 그래프의 X축은 시간, Y축은 주파수에 대응된다. 상대적으로 구조가 크고, 회전 날개의 회전속도가 빠른 MC-5 드론의 반사 신호는 도플러 편이의 간격이 크고 회전 간격이 명확하게 드러난다. 반면 작고 날개의 회전속도가 느린 팬텀-3는 도플러 편이 구간이 불규칙하며 약하게 표현된다. 실제 비행하는 드론에서는 불규칙한 비행 속도 및 이에 따른 날개 회전을 변화로 인해 반사 패턴의 형태가 더욱 복잡한 형태로 수집될 것이다[11]. 따라서 드론의 이동에 따른 다양한 시나리오를 고려할 필요가 있다.




Fig. 5 (a)Phantom-3 (b)MC-5 Micro-Doppler

3.2. KNN을 통한 드론 마이크로 도플러 분류

도플러 분류 기반의 드론 탐지 기술은 다양한 환경 변수에 기인하기 때문에 레이더 수신 신호를 분석하여 드론 표적을 식별하기 위해서는 고차원의 패턴 인식 기술이 요구된다. 드론 로터에 의한 도플러 변이 패턴은 비교적 단순하므로 입력 변수가 적은 시나리오에 적합한 KNN(K-Nearest Neighbors) 방식을 적용하였다.

일반적으로 기계학습을 적용하기 위해서는 충분한 실험 데이터를 확보해야 한다. 마이크로 도플러 신호는 1차원상의 패턴 변화를 단일 드론 비행에서도 충분히 확보할 수 있다. 그림 6과 같이 마이크로 도플러 패턴의 주기 특성에 착안하여 시간 축으로 균등한 샘플 개수로 분할하여 데이터 균을 구축하였다. 이후 두 개의 팬텀-3와 MC-5 드론을 서로 구분할 수 있도록 KNN 알고리즘에 데이터를 학습시켰다. 본 논문에서는 드론의 이동 속도라 일정하다고 가정하여 반사 패턴의 변화율을 최소화함으로써 소요되는 학습 데이터의 수를 최소화하였다. 기존 레이더 기반의 기계학습을 적용한 기존 드론 분류

연구[8-10] 사례를 고려하여 실험 드론에 대한 학습 데이터는 931개, 테스트 데이터는 51개를 설정하였다.

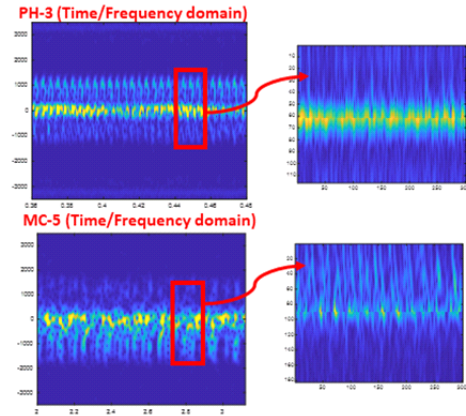


Fig. 6 Test data selection for KNN Algorithm

KNN은 유형을 알고 있는 데이터에 특정 분류 기준을 할당하기 위한 모델링 기법이다. 새로운 입력 데이터에 대해 기존 데이터 중에서 가장 유사한 K개의 데이터를 이용하여 새로운 데이터의 클래스를 예측한다. 알고리즘 구현을 위해 구글에서 제공하는 오픈 소스 라이브러리 텐서플로우를 사용하였다.

그림 7은 KNN 알고리즘을 흐름도를 보인다. 기존에 주어진 학습 데이터와의 입력된 데이터 간의 유클리드인 거리를 계산하여 최소거리를 선택한다. 이때 K개의 군집에 따라 라벨이 결정되며, 분류기에 의한 분류가 되었다고 정의한다. 최종적으로 분류된 라벨의 예측값과 정확도를 결과로 도출하게 된다.

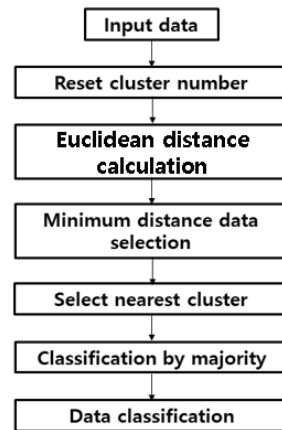


Fig. 7 KNN Algorithm block diagram

학습된 결과와 비교하여 테스트 데이터의 분류 성능을 시험하였다. 표 2는 K값 변화에 따른 드론 분류 정확도를 보인다. K가 적절한 값보다 작을 경우 주변 데이터들의 특성을 충분히 고려하지 못해서 나타나는 과적합 현상이 나타나며, 반대로 지나치게 증가하면 주변 데이터 이외의 특성에 집중하여 과소적합 현상이 발생한다. 따라서 K의 값의 변화에 따른 정확도를 확인하는 과정이 중요하다.

Table. 2 Simulation parameter

K	Accuracy
3	84.3%
5	90%
7	92%
9	88.2%

표 2에서 볼 수 있듯이 K값 증가에 따라 정확도가 비선형적으로 변화하기 때문에 적절한 K값의 설정이 요구된다. 드론의 실험 데이터를 기반으로 학습한 결과 K값을 7로 설정할 때 가장 높은 정확도를 보였으며, 평균 정확도는 88.7%, 변량의 값은 8.4였다.

3.3. CNN을 활용한 드론 ISAR 영상 분류

마이크로 도플러는 드론의 불규칙한 이동 변화에 따른 패턴의 가변성으로 인해 신뢰도가 낮아질 수 있다는 한계가 있다. 이를 극복하기 위해 본 논문에서는 드론의 형상을 수집할 수 있는 ISAR 영상을 이용한 분류 방법을 도입한다. ISAR 영상을 실측하는 과정은 매우 까다롭고 시간 소요가 많기 때문에 기계학습에 충분한 데이터를 확보하기 어렵다. 따라서 실측 데이터에 기반한 모의 ISAR 영상을 생성하는 방식으로 기계학습 데이터를 확보하였다. 생성된 데이터에 대한 신뢰도를 높이기 위해 실험적으로 드론 ISAR 영상을 획득한 사례에서 수집된 경로 데이터를 사용하여 다양한 시나리오의 모의 ISAR 영상을 생성하였다[11,12]. 그림 8은 왼쪽부터 팬텀-3와 MC-5 드론에서 추출한 ISAR 영상을 각각 보인다[11]. 반사도가 낮은 소형 팬텀-3 드론에서는 반사파가 약해서 클러터에 취약하고 상대적으로 요동이 심해 표적 형상 정보가 왜곡되는 형태로 나타난다. 상대적으로 큰 구조물인 MC-5 드론은 비교적 선명한 모습을 보이지만 ISAR 영상의 해상도가 10cm를 초과하기 때문에 두 경우 모두 프로펠러의 형상을 파악하기는 어렵다.

따라서 육안 식별보다는 패턴 형상을 추출하여 식별하는 것이 바람직하며 이를 위해서는 기계학습의 적용이 적절한 수단이 될 수 있다.




Fig. 8 Drone ISAR Experimental images

CNN(Convolutional Neural Network)은 영상처리를 위해 개발된 다층 신경망의 일종으로, 신경망의 구조를 개선하여 복잡도를 개선한 이미지 인식에 사용되는 기법이다. 다층 신경망의 입력 데이터는 1차원의 배열 구조로 한정된다. 이러한 비효율성의 한계를 개선하기 위해 도입된 개념이 CNN으로, 복잡도를 개선하고 영상의 공간 정보를 보존하여, 정확도를 확보할 수 있다. ISAR는 2차원의 구조 형상이 불규칙하게 변형되어 얻어지므로 패턴 인식보다는 영상 인식 알고리즘을 적용하는 것이 타당하다. 따라서 영상 학습 알고리즘에 적합한 CNN을 선택하여 적용하였다. 고해상도 ISAR 영상을 CNN 알고리즘에 적용하기 위해서는 충분한 수량의 영상 자료가 필요하다. 그러나 마이크로 도플러 패턴과는 달리 ISAR 영상은 수행되는 단일 실험에서 오직 한 개의 영상을 생성하기 때문에 충분한 학습 데이터 생성이 어렵다. 이를 보완하기 위해 본 연구에서는 실험 환경과 유사한 모의 실험을 통해 ISAR 영상 데이터 군을 생성하는 방법을 대안으로 고려하였다.

비행경로에 따른 드론의 ISAR 영상을 반복적으로 생성하기 위해 비행 경로에 대해 다양한 불규칙 변화 특성을 적용하여 각 시나리오에서 서로 다른 ISAR 영상을 생성하였다. 모의실험에 적용한 환경 변수는 표 3과 같다. 그림 11의 흐름도를 통해 ISAR 영상 데이터를 생성하여 CNN 알고리즘에 적용하였다.

드론을 구분하는 주요 특성으로 로터의 크기와 모양을 설정하고 각각 차별화된 규격을 갖는 3대의 드론을 실험 대상으로 설정하였다. 드론의 대각선 길이는 A,B,C 각각 10.4m, 18m, 11m의 규격을 갖는다. 시뮬레이션을 통해 생성한 드론의 ISAR 영상은 그림 9와 같다. 그림 9(A), (B)는 크기가 다른 쿼드콥터를 나타내며, 그림

9(C)는 헬사콥터를 나타낸다.

Table. 3 ISAR Simulation parameters

Parameters	Values
Radial velocity	70 m/s
Center Frequency	10 GHz
Bandwidth	128 MHz
PRF	20 KHz
Angular velocity	0.06 rad/s
Radial acceleration	0.1 m/s ²
Initial Radial distance	16 Km




Fig. 9 Results of drone ISAR simulations
(a) Quad-copter1, (b) Quad-copter2, (c) Hexa-copter

드론의 요동이 비교적 적은 경우에는 형상이 선명하게 드러나지만, 요동 지수를 높이면 영상 합성 과정에서 오류가 증가하며 형상이 왜곡되고 잡음 지수가 증가하게 된다. 본 연구에서는 충분한 학습 데이터를 확보하기 위해 드론의 비행 각속도에 가우시안 분포를 따르는 무작위 함수를 적용하여 데이터 군을 생성하였다. 그림 10은 비행 각속도 무작위성에 따른 각 드론의 ISAR 영상이다. 가장 오른쪽의 ISAR 영상과 같이 요동의 정도가 커지면 ISAR 영상을 육안으로 식별하기 어려워지며, 이는 드론뿐만 아니라 다른 비행체와 오인될 확률이 높은 데이터로 간주할 수 있다. 학습 데이터군의 신뢰성을 높이기 위해 드론 ISAR 영상으로 판별되기 어려운 데이터군을 추가하였다.




Fig. 10 Data set based on experimental environment

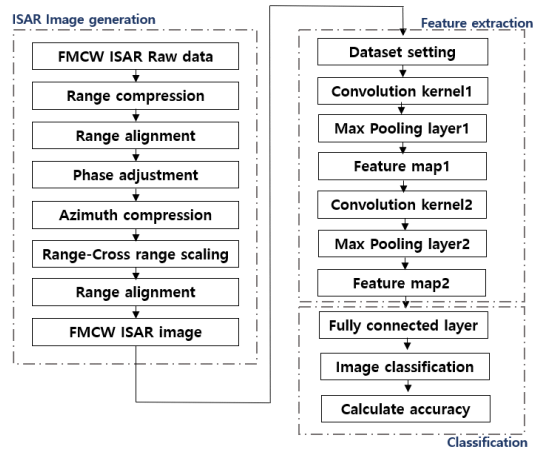


Fig. 11 CNN Processing of drone ISAR

CNN은 다수의 컨볼루션 층과 서브샘플링 층(Subsampling layer)으로 구성된다. 컨볼루션 층은 필터를 통해 입력 정보에 대한 특징을 추출하는 역할을 한다. 이때 필터의 크기에 따라 입력 영상을 스캔하며 합성곱을 수행하여 특징 맵을 생성한다. 서브샘플링 층은 컨볼루션 층에서 만들어진 특징 맵에 대해서 공간적 해상도를 줄인 뉴런 층이다. 해당 단계는 차원을 축소하는 과정으로, 이를 통해 복잡도를 줄일 수 있다. 서브샘플링 연산자로는 대상 뉴런들에 대해 최대치를 취하는 맥스 풀링 연산자나 평균치를 취하는 평균풀링 연산자를 주로 이용한다. 그림 12는 본 연구에서 사용한 CNN 알고리즘 모델의 구성이다. 입력으로 사용한 드론 ISAR 영상의 크기는 각각 (128×128), 서브샘플링 필터는 (3×3)로 설정하였다. 두 개의 컨볼루션 층으로 학습 단계를 구성하였다. 통상적으로 구성된 모델에 전체 데이터를 한 번에 학습시키지 않는다. 이는 메모리 한계와 속도 저하를 유발하기 때문에 대부분의 기계학습에서는 데이터를 분할하여 반복 학습하는 방식을 택한다. 전체 데이터 군을 하나의 소단위로 나누는 단위를 배치 크기(Batch size)라고 한다. 배치 크기의 설정에 따라 학습 결과가 달라지기 때문에 적절한 배치 크기의 설정이 요구된다[12]. 해당 알고리즘에서는 과소적합과 과적합이 발생하지 않는 범위 내에서 배치 크기를 10으로 설정하여 50번의 학습을 수행하였다.




Fig. 12 CNN Processing

학습 모델에 적용하기 위해 세 개의 드론에 대해 학습 데이터는 120개씩 총 360개를, 테스트 데이터는 40개씩 총 120개를 생성하였다. 먼저 비행 각속도를 상수로 설정하여 생성한 ISAR 데이터 군에 대한 CNN 학습 결과는 98%의 정확도를 확인하였다. 이는 이상적인 데이터 군으로 실제 실험 환경을 충분히 반영하지 않은 결과이다.

이를 보완하기 위해 실제 환경과 유사하도록 비행 각속도 변화를 가하여 왜곡된 데이터 군을 생성하였다. 앞선 이상적인 시나리오와 달리 데이터 군의 다양성으로 CNN 학습에 사용되는 데이터 군의 선정에 따라 모델의 성능이 달라진다. 세 번의 실험을 수행하였으며, 정확도와 손실함수를 통해 모델의 훈련 성능을 평가하였다. 그림 13은 세 번의 실험 결과 중 가장 높은 정확도를 보인 첫 번째 실험의 결과이다. 학습 데이터와 검증 데이터의 정확도는 1에 유사하게 수렴하였으며, 최종 정확도는 94%이다. 손실함수는 0에 수렴하여 훈련 모델 적합도가 우수하다고 할 수 있다.

세 번의 실험에 대한 모델 성능 평가 지표인 정밀도, 재현율, 정밀도와 재현율의 조화평균값을 출력하였다. 표 4와 같이 정확도와, 재현율, 정밀도, 정밀도와 재현율의 조화평균값의 값의 균형을 이루는 것을 확인할 수 있다. 이상적인 시나리오에 비하여 낮은 정확도를 출력하였지만, 이는 모델의 훈련 성능, 평가 성능을 신뢰할 수 있음을 의미한다.

Table. 4 Evaluation metrics

Test (%)	Accuracy	Precision	Recall	F1 score
1	94.2	94.1	93.2	93.7
2	92.5	91.3	90.6	90.9
3	91.7	89.3	88.0	88.7

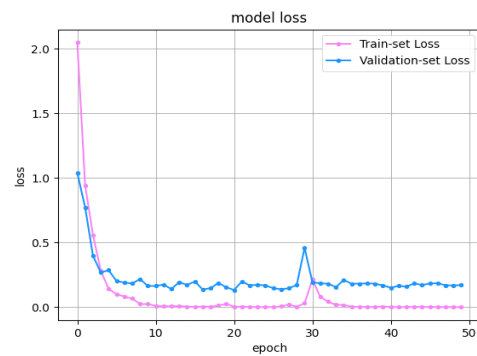
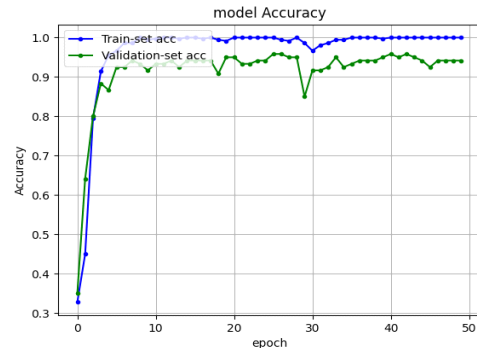


Fig. 13 Accuracy, Loss function

IV. 결론

낮은 반사도를 갖는 드론은 새와 같은 생물체나 클러터 등과 구별되어야 하며 이를 위해서는 단순 레이더 탐지에서 나아가, 복합적인 센서 네트워크 구성을 통해 드론의 탐지 및 식별까지 가능해져야 한다. 본 논문에서는 드론 탐지 실험 데이터를 기반으로 마이크로 도플러 특성 ISAR 영상을 생성하여 기계학습을 적용한 드론 탐지 및 식별 가능성을 제시하고 정확도를 분석하였다.

본 논문에서는 실험 데이터를 기반으로 마이크로 도플러를 생성하여 KNN 알고리즘과 접목하여 정확도를 분석하였다. 마이크로 도플러 영상은 단거리 탐지에 유효하여 실제 환경에서는 활용도가 낮다. 또한 드론의 마이크로 도플러 패턴은 환경 변수에 취약하여 정확도를 개선하기 어렵다. 이를 보완하기 위해 장거리 탐지에 유효하며 고해상도 영상을 생성할 수 있는 ISAR 영상을 활용하여 분류의 정확도를 확보하고자 하였다.

본 논문에서는 임의의 경로를 갖는 드론 비행 시나리

오에서 ISAR 영상을 생성하고 획득된 영상을 CNN 알고리즘에 적용하였다. ISAR 영상은 충분한 데이터 베이스를 확보하기가 어려우므로 모의실험을 통해 학습데이터를 생성하였다. 다양한 종류의 드론에 대해 ISAR 영상을 실험적으로 확보하고 이를 바탕으로 모의실험을 수행하여 생성된 학습 데이터를 CNN 알고리즘에 적용하여, 우수한 드론 탐지 및 식별 성능을 검증하였다.

실제 실험에서 측정된 ISAR 영상을 테스트 데이터로 입력하여 CNN을 수행하는 것은 국내외적으로 한 번도 시도된 바가 없어 매우 큰 의미를 갖는다. 본 연구는 레이더 영상 기반의 드론 분류 가능성을 제시하였으며, 향후 실제 측정 데이터를 사용하여 ISAR 영상 기반 드론 식별을 수행하는데 기여할 수 있을 것이다. 향후에는 보다 많은 드론 모델 및 이동하는 새와 같은 확장된 표적군과의 비교 모델을 수립하는 추가 연구가 필요할 것이다.

ACKNOWLEDGEMENT

This work has been supported by Civil-Military Technology Cooperation Program in South Korea.

REFERENCES

[1] S. Rahman and D. A. Robertson, "Radar micro-Doppler signatures of drones and birds at K-band and W-band," *Scientific Reports*, vol. 8, no. 1, pp. 1-11, 2018.

[2] S. Björklund, "Target detection and classification of small drones by boosting on radar micro-doppler," *2018 15th European Radar Conference (EuRAD)*, IEEE, pp. 182-185, 2018.

[3] F. Hoffmann, M. Ritchie, and F. Fioranelli, "Micro-Doppler based detection and tracking of UAVs with multistatic radar," *2016 IEEE Radar Conference (RadarConf)*, IEEE, pp. 1-6, 2016.

[4] B. Taha and A. Shoufan, "Machine learning-based drone detection and classification: State-of-the-art in research," *IEEE Access*, vol. 7, pp. 138669-138682, 2019.

[5] P. Klaer, A. Huang, P. Sévigny, S. Rajan., S. Pant, P. Patnaik, and B. Balaji, "An Investigation of Rotary Drone HERM Line Spectrum under Manoeuvring Conditions," *Sensors2020*, vol. 20, no. 20, pp. 5940, 2020.

[6] M. Ezuma, F. Erden, C. K. Anjinappa, O. Ozdemir, and I.

Guvenc, "Micro-UAV detection and classification from RF fingerprints using machine learning techniques," *2019 IEEE Aerospace Conference*, IEEE, pp. 1-13, 2019.

[7] S. Rahman and D. A. Robertson, "Multiple drone classification using millimeter-wave CW radar micro-Doppler data," *Radar Sensor Technology XXIV., International Society for Optics and Photonics*, vol. 11408, pp. 1140809, 2020.

[8] H. Kang, B. K. Kim, J. S. Park, J. S. Suh, and S. O. Park, "Drone Elevation Angle Classification Based on Convolutional Neural Network With Micro-Doppler of Multipolarization," *IEEE Geoscience and Remote Sensing Letters*, 2020.

[9] D. A. Brooks, O. Schwander, F. Barbaresco, J. Y. Schneider, and M. Cord "Temporal deep learning for drone micro-Doppler classification," *2018 19th International Radar Symposium (IRS)*, pp. 1-10, 2018.

[10] S. Rahman and D. A. Robertson "Classification of drones and birds using convolutional neural networks applied to radar micro-Doppler spectrogram images," *IET Radar, Sonar & Navigation*, vol. 14, no. 5, pp. 653-661, 2019.


[11] K. M. Song, M. J. Moon, and W. K. Lee, "Experimental Study of Drone Detection and Classification through FMCW ISAR and CW Micro-Doppler Analysis," *Korea institute of military science and technology*, vol. 21, no. 2, pp. 147-157, 2018.

[12] P. M. Radiuk, "Impact of training set batch size on the performance of convolutional neural networks for diverse datasets," *Information Technology and Management Science*, vol. 21, no. 1, pp. 20-24, 2017.



문민정(Min-Jung Moon)

전자통신공학과 공학박사
2016년 2월 : 한서대학교 항공전자공학과(공학사)
2019년 2월 : 한국항공대학교 항공전자정보공학과(공학석사)
2019년 2월~2020년 3월 : 항공전자연구소
※ 관심분야: SAR 신호처리, 위성 SAR, 드론 SAR



이우경(Woo-Kyung Lee)

1994년 2월 : KAIST 전기및전자(공학사)
1996년 2월 : KAIST 전기및전자 (공학석사)
1999년 12월 : 런던대학교(UCL) 전기전자공학과(공학박사)
1999년 10월~2002년 12월 : 한국과학기술원 인공위성센터 연구교수
2004년 9월 ~ 현재 : 한국항공대학교 항공전자정보공학과 교수
※ 관심분야 : 드론 SAR, 위성탐지체, SAR 영상, SAR 신호처리, 위성 SAR, 원격탐사