

# 미세 도플러 영상을 이용한 심층학습 표적 분류 기법 성능 분석

김지현\*, 박도현\*, 김형남<sup>o</sup>

## Performance Analysis of Deep-Learning Target Classification Algorithms Using Micro-Doppler Images

Ji-Hyeon Kim\*, Do-Hyun Park\*, Hyoung-Nam Kim<sup>o</sup>

### 요약

미세 도플러 (micro-Doppler) 변조는 각 개체의 구분 및 각각의 움직임에 대한 미세한 운동 상태를 나타내는 표적 특징으로서, 표적을 인식하고 분류하는 기술에 활용되고 있다. 미세 도플러 주파수는 물체의 회전과 진동 등의 기본적인 운동 특징에 의한 도플러 주파수의 변조 형태로 나타나며, 이를 이용하면 높은 표적 인식 정확도로 표적을 추적하고 분류할 수 있다. 본 논문에서는 드론, 조류, 사람 표적에 따른 미세 운동 신호를 모델링하고, 미세 도플러 영상을 통해 시간-주파수 영역에서 분석하여 표적의 미세 도플러 특징을 확인한다. 그리고 서로 다른 미세 운동을 하는 표적을 분류하기 위해 미세 도플러 영상을 입력으로 하는 AlexNet, VGGNet16, GoogLeNet, ResNet34의 4가지 심층 신경망을 적용한다. 모의실험을 통해 각 표적의 레이더 실측 데이터 입력 세트에 따른 심층학습 알고리즘의 분류 성능을 분석한다. 모의실험 결과는 4가지 신경망 모두 87% 이상의 분류 정확도 성능을 가지며, ResNet34의 경우, 정확도, 정밀도, 재현도 3가지 척도에서 90% 이상의 성능으로 표적 분류 성능이 가장 우수함을 보인다.

**Key Words** : Micro-Doppler, characteristic vector, target classification, target detection, deep learning algorithm

### ABSTRACT

Micro-Doppler modulation is a target signature that represents micro-motion state for each individual movement, it is used in the technology of recognizing and classifying targets. The micro-Doppler frequency appears in the form of transition of the Doppler frequency by basic movement characteristics such as rotation and vibration of an object, and thus it can make it possible to track a target and classify it with high recognition accuracy. In this paper, we model micro-motion signals of a drone, a bird, and human targets, and analyze them in the time-frequency domain through micro-Doppler images to confirm the micro-Doppler images to confirm the micro-Doppler characteristics of the target. To classify targets performing micro-movement, we apply four deep neural networks, such as AlexNet, VGGNet16, GoogLeNet, and ResNet34, to micro-Doppler images input. Through simulation, we analyze the classification performance of deep learning algorithms

※ 2017학년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No.2017RID1A1B04035230)

• First Author : Department of Electronics Engineering, Pusan National University, kjihyeon@pusan.ac.kr, 학생회원

o Corresponding Author : Department of Electronics Engineering, Pusan National University, hnkim@pusan.ac.kr, 종신회원

\* Department of Electronics Engineering, Pusan National University, dohpark@pusan.ac.kr, 학생회원

논문번호 : 202011-286-A-RN, Received November 16, 2020; Revised December 30, 2020; Accepted December 31, 2020

according to the radar measurement data input set of each target. Simulation results show that all four neural networks have more than 87% classification accuracy performance, and in the case of ResNet34, target classification performance is the best with more than 90% performance on three scales of accuracy, precision and recall.

## I. 서 론

최근 상용 방송 및 통신 신호를 활용하여 표적을 탐지하는 수동형 레이더 시스템에 대한 연구가 활발히 진행되고 있다<sup>1,3</sup>. 상용 방송 및 통신 목적으로 송신기에서 송출된 신호는 이동하는 표적에 부딪쳐 반사될 수 있으며, 수동형 레이더 시스템은 이러한 표적 반사 신호를 이용하여 표적의 위치 및 속도를 추정한다<sup>4</sup>.

표적 탐지 및 추적의 정확도를 높이기 위해서는 클러터와 같은 신호를 제거하여 미약한 표적 신호를 추출하여야 한다. 또한, 다양한 종류의 표적이 존재할 때, 여러 표적을 추적하고 분류할 필요성이 있다. 그러나 위치, 속도 등과 같은 기존 수동형 센서 기반의 측정치로는 표적 인식의 한계가 있으며, 이를 극복하기 위해서 추가적인 표적 특징을 나타내는 파라미터에 대한 연구가 필요하다.

표적 신호에는 표적이 이동하는 상대속도로 인해 신호의 주파수가 변하는 도플러 효과 (Doppler effect)가 나타난다. 이 때, 표적의 거리 이동 외에 표적 개체가 진동, 회전 등의 미세 운동을 하게 되는데, 이러한 미세 운동으로 인한 미세 도플러 효과 (micro-Doppler effect)가 발생한다. 이 미세 도플러 신호가 다양한 표적에 따라 고유한 특징이 있는 점을 이용하여 민간 및 군사 분야에서 미세 운동 파라미터 추정, 표적 인식 등에 대한 연구가 진행되고 있다.

미세 도플러 (micro-Doppler)는 시간에 따른 레이더 반사 신호를 임의의 영역에 한정해 푸리에 변환을 하고 이를 시간지연을 통해 반복하는 STFT (short-time Fourier transform)을 이용하여 시간-주파수 축의 미세도플러 영상으로 나타낼 수 있다<sup>5</sup>. 미세 도플러 영상은 표적의 미세 운동 주파수, 초기 위상을 가진 정현파의 조합으로 표현되며, 시간에 따른 표적 각 부분의 즉각적인 운동변화와 표적의 운동주기와 같은 고유 특징을 발견할 수 있다. 레이더 반사 신호의 경우에는 레이더의 LOS (line of sight) 방향에 대한 표적 각 부분의 속도 변화를 2차원 이미지로 추출할 수 있다.

기존의 미세 도플러 신호처리 기법들은 미세 도플러 특징을 2차원의 시간-주파수 영역에서 분석하고,

언어낸 주파수를 이용한 식별에 중점을 두었다. 그러나 표적의 미세 운동 종류가 다양하거나, 속도가 비슷한 서로 다른 표적을 분류할 경우, 각 표적의 종류를 구분하기 어려운 단점이 있다. 따라서 높은 분류 성능을 얻기 위해서는 각 표적의 미세 도플러 신호를 정교하게 모델링하고, 이 신호를 바탕으로 구해진 미세 도플러 영상에 기계학습을 적용하여 특징을 효과적으로 추출하고 분류할 필요성이 있다.

본 논문에서는 다양한 표적의 미세 도플러 특성벡터 추출을 위해 드론 블레이드의 회전운동, 조류의 날갯짓, 보행자의 걷는 행동에 따른 미세 도플러 신호를 모델링하고, 미세 도플러 주파수 특성을 확인한다. 그리고 서로 다른 미세 운동을 하는 표적을 분류하기 위해 미세 도플러 영상을 입력으로 하여 심층학습 (deep learning) 알고리즘을 적용한다. 알고리즘은 AlexNet, VGGNet16, GoogLeNet, ResNet34를 사용하며 4가지의 심층학습 분류 알고리즘을 이용한 표적 분류 성능을 비교, 분석한다.

본 논문의 구성은 다음과 같다. 2장에서는 표적의 종류에 따른 신호 모델링 및 미세 도플러 주파수 특징에 대해 설명한다. 3장에서는 표적 분류를 위한 심층학습 알고리즘 4가지에 대해 소개한다. 이후 4장에서는 모의실험을 통해 4가지 심층학습 알고리즘의 표적 분류 성능을 분석하고, 5장에서 본 논문의 결론을 맺는다.

## II. 신호 모델링 및 미세 도플러 특성

### 2.1 미세 운동 모델링<sup>5,6</sup>

드론 블레이드의 회전운동 기하구조는 그림 1과 같다. 송신기와 수신기 사이의 거리가 동일한 지점에 배치되었다고 가정한다. 송신기의 좌표는 원점에 고정되어 있고  $(X_0, Y_0, Z_0 = 0)$ , 수신기가  $X$ 축으로  $B_L$ 만큼 분리된 동일한 평면에 배치된 경우 수신기의 위치는  $(B_L, 0, 0)$ 이다.  $Z$ 축 중심으로 4개의 블레이드가 회전 속도  $\theta$ 로 회전 운동하는 형태이다. 각 블레이드의 위치 벡터는 다음과 같이 정의할 수 있다.

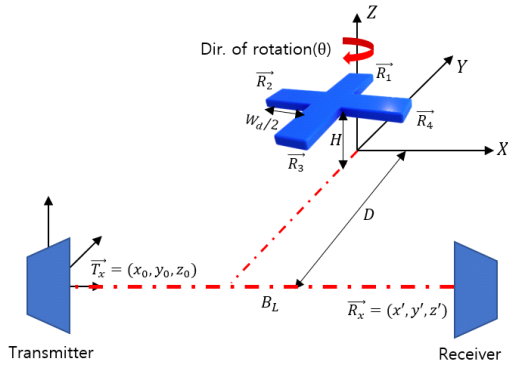


그림 1. 드론 블레이드의 기하구조  
Fig. 1. Geometry of the drone blades.

$$\begin{aligned} \vec{R}_1 &= \left[ \left( \frac{B_L}{2}, D, H \right) \right] \\ \vec{R}_2 &= \left[ \left( \frac{B_L}{2} + \frac{W_d}{2}, D - \frac{W_d}{2}, H \right) \right] \\ \vec{R}_3 &= \left[ \left( \frac{B_L}{2}, D - W_d, H \right) \right] \\ \vec{R}_4 &= \left[ \left( \frac{B_L}{2} - \frac{W_d}{2}, D - \frac{W_d}{2}, H \right) \right] \end{aligned} \quad (1)$$

여기서  $D$ 는 송수신기로부터 가장 먼 블레이드까지의 거리이며,  $W_d$ 는 드론 블레이드의 너비이다. 이 때, 블레이드의 위상 함수는 식 (2)와 같이 구할 수 있다<sup>5)</sup>.

$$\Phi(t) = \frac{2\pi}{\lambda} \frac{W_d}{2} \cos\left(\frac{\beta}{2}\right) \cos(\delta) \cos(\Omega t + \theta_0) \quad (2)$$

식 (2)에서  $\lambda$ 는 파장이며,  $\beta$ 는 송수신기 사이의 각도를 의미한다.  $\left[ \cos\left(\frac{\beta}{2}\right) \cos(\delta) \right]$ 는 바이스테틱 기하구조의 계수 항을 나타내고,  $\Omega$ 와  $\theta_0$ 는 블레이드의 회전율과 초기 회전각이다.

조류의 날갯짓 운동 모델은 그림 2와 같다.  $xyz$  평면의 원점을 조류의 몸통으로 두고  $L_1$ 의 길이를 가지는 날개 상단 (상완)과  $L_2$ 의 길이를 가지는 날개 하단 (하완)이 운동주기  $f_{flap}$ 으로 날갯짓하는 형태이다. 조류의 운동주기와 시간에 따른 미세운동을 식 (3), (4)와 같이 표현할 수 있다<sup>5)</sup>.

$$\begin{pmatrix} \psi_1 \\ x_1 \\ y_1 \\ z_1 \end{pmatrix} (t) = \begin{pmatrix} 40 \cos(2\pi f_{flap} t) + 15 \\ 0 \\ L_1 \cos \psi_1(t) \\ y_1(t) \tan \psi_1(t) \end{pmatrix} \quad (3)$$




그림 2. 조류의 날갯짓 미세 운동 모델  
Fig. 2. A kinematic model of a bird wing.

$$\begin{pmatrix} \psi_2 \\ x_2 \\ y_2 \\ z_2 \end{pmatrix} (t) = \begin{pmatrix} 30 \cos(2\pi f_{flap} t) + 40 \\ 20 \cos(2\pi f_{flap} t) \\ - (y_2(t) - y_1(t)) \cdot \tan(\phi_2(t) / \cos(\psi_1(t) - \psi_2(t))) \\ L_1 \cos \psi_1(t) + L_2 \cos \phi_2(t) \cdot \cos(\psi_1(t) - \psi_2(t)) \\ z_1(t) + (y_2(t) - y_1(t)) \cdot \tan(\psi_1(t) - \psi_2(t)) \end{pmatrix} \quad (4)$$

여기서  $\psi_1$ 은 상완의 각도,  $\psi_2$ 는 상완에 대한 하완의 각도이며,  $\phi_2$ 는 하완의  $x$ 축에 대한 변화 각도를 의미한다.  $P_1, P_2$ 는 상완과 하완 끝부분의 좌표이다.

그림 3은  $xyz$  평면의 원점을 사람의 척추 골반 중심으로 두었을 때, 보행자의 미세 운동 모델을 나타낸다. 사람의 걷는 행동을 통해 원형으로 표시된 머리, 어깨, 팔꿈치, 무릎, 발목 등으로 나뉜 신체 부위가 미세 운동하는 형태이다. 사람이  $V_R$ 의 속도로 보행하는 경우, 보행 사이클의 길이  $R_c$  및 사이클 지속 시간  $T_c$ 는 식 (5)를 이용하여 구할 수 있다.




그림 3. 보행자의 신체 미세 운동 모델  
Fig. 3. A kinematic model of human walking.

$$\begin{aligned} R_c &= 1.346 \times \sqrt{V_R}, \\ T_c &= R_c / V_R. \end{aligned} \quad (5)$$

보행자가 걸음을 걸을 때 다리의 앞뒤 이동에 의한 미세 운동은 식 (6)으로 표현할 수 있다<sup>6-8)</sup>. 또한, 다리의 앞뒤 이동을 만들기 위해 일어나는 골반의 앞뒤/좌우/회전 운동을 식 (7)과 (8)에 나타내었다. 여기서  $t_R$ 은 한 걸음의 지속 시간으로 정규화한 시간을 의미한다.

$$\begin{aligned} Tr_{F/B} &= a_{F/B} \sin(2\pi(2t_R + 2\phi_{F/B})), \\ a_{F/B} &= \begin{cases} -0.084 V_R (V_R - 1) & (V_R < 0.5) \\ -0.021 & (V_R > 0.5) \end{cases}, \\ \phi_{F/B} &= 0.768 - 0.752 T_C, \\ t_R &= t / T_C. \end{aligned} \quad (6)$$

$$\begin{aligned} \begin{pmatrix} Ro_{F/B} \\ Ro_{Tor} \end{pmatrix} &= \begin{pmatrix} -ar_{F/B}(1 - \sin(2\pi(2t_R - 0.1))) \\ -4V_R \cos(2\pi t_R) \end{pmatrix}, \\ ar_{F/B} &= \begin{cases} -8V_R^2 + 8V_R & (V_R < 0.5) \\ 2 & (V_R > 0.5) \end{cases}. \end{aligned} \quad (7)$$

$$\begin{aligned} R_{0/L/R} &= \begin{cases} -ar_{L/R}(1 - \cos(2\pi(10t_R/3))) & (0 \leq t_R < 0.15) \\ -ar_{L/R}(1 + \cos(2\pi(10(t_R - 0.15)/7))) & (0.15 \leq t_R < 0.5) \\ -ar_{L/R}(1 + \cos(2\pi(10(t_R - 0.5)/3))) & (0.5 \leq t_R < 0.65) \\ -ar_{L/R}(1 - \cos(2\pi(10(t_R - 0.65)/7))) & (0.65 \leq t_R < 1) \end{cases}, \\ ar_{L/R} &= 1.66 V_R. \end{aligned} \quad (8)$$

### 2.2 표적에 따른 미세 도플러 특징

드론, 조류, 보행자와 같은 표적들은 서로 다른 미세 운동을 하므로 표적의 종류에 따라 미세 도플러 특징이 다를 것이라 예상할 수 있다. 본 절에서는 시간-도플러 영역에서의 미세 도플러 영상을 통해 세 표적의 미세 도플러 특징을 확인한다.

미세 도플러 영상은 수집된 반사 신호를 바탕으로 식 (9)와 같이 short-time Fourier transform (STFT)을 적용하여 얻을 수 있다.

$$STFT(t, f) = \int_{-\infty}^{\infty} x(u)h^*(u-t)e^{-j2\pi fu} du. \quad (9)$$

여기서  $x$ 는 수집된 반사 신호이며  $h^*(u-t)$ 는 시간 축에서 신호를 분할하기 위한 윈도우 함수이다<sup>7)</sup>.

먼저, 드론 블레이드의 회전 운동에 따른 미세 도플러 영상을 그림 4에 나타내었다. 수집 시간은 1초이며, 4개의 블레이드가 2 r/s의 속도로 회전한다. 두 블레이드 사이의 각도는 90°이므로 도플러 주파수 축에서 4개의 정현파 곡선이 서로 교차하는 특징을 확인할

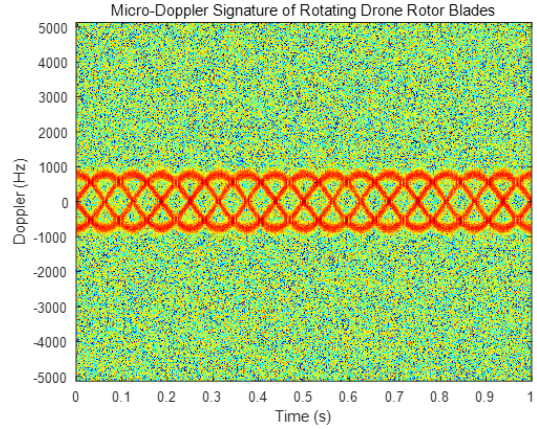


그림 4. 회전하는 드론 블레이드의 미세 도플러 특징  
Fig. 4. Micro-Doppler signature of rotating drone rotor blades.

수 있다. 또한, 수집 시간 1초 동안 2개의 정현파 곡선이 겹치는 패턴이 8번 나타나는 것을 확인할 수 있는데, 이는 블레이드의 개수와 회전 속도의 곱을 나타내며, 각 패턴 간의 간격은 0.125초임을 얻을 수 있다.

그림 5는 조류의 날갯짓 운동에 따른 미세 도플러 영상을 나타낸다. 조류의 미세 운동은 상대적으로 속도가 느리기 때문에 수집 시간을 10초로 하였고, 1.0 m/s의 속도로 날아간다. 미세 도플러 영상에서 날개의 상완과 하완의 미세 도플러 특징이 혼합된 것을 확인할 수 있다. 수집 시간 10초 동안 10개의 패턴이 나타나는 것을 통해 조류의 날갯짓 운동 빈도가 1.0 Hz임을 알 수 있다. 또한, 시간이 흐를수록 표적이 수신 레이더에 가까이 근접함에 따라 상대 속도와 입사되는 신호의 방향이 변화하게 되고, 그로 인해 도

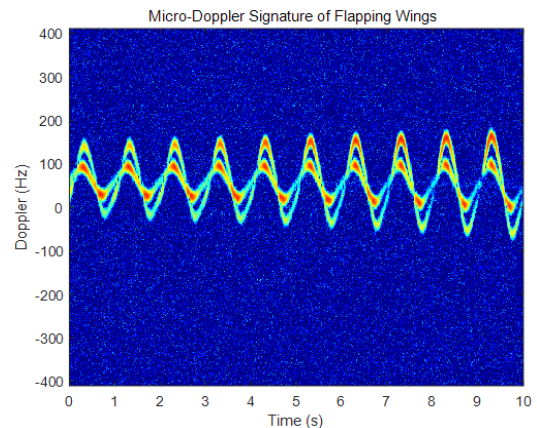


그림 5. 날갯짓하는 조류의 미세 도플러 특징  
Fig. 5. Micro-Doppler signature of flapping wings.

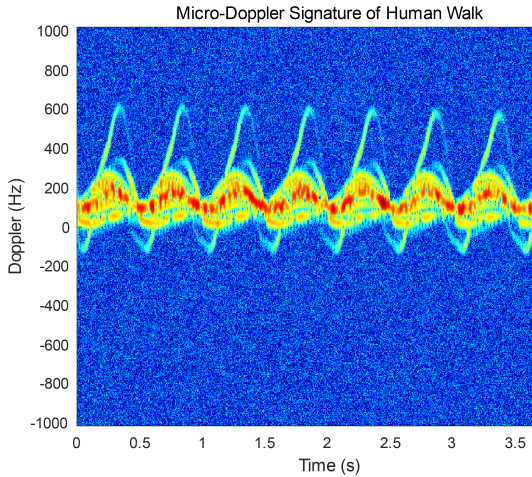


그림 6. 보행자의 미세 도플러 특징  
Fig. 6. Micro-Doppler signature of human walk.

플러 특징 파형의 진폭이 커지는 현상이 나타난다. 그림 6은 사람의 걷는 행동에 따른 미세 도플러 영상을 나타낸다. 수집 시간은 4초이며, 1.0 m/s의 속도로 보행하는 사람의 몸통 및 하체 움직임 신호에 대한 미세 도플러 특징을 확인할 수 있다. 가장 큰 피크는 앞으로 걷는 다리의 움직임을 나타내며, 한 번의 보행 사이클은 왼쪽과 오른쪽 다리의 움직임으로 완성된다. 그 외에 경골, 몸통 등의 미세 운동 신호가 혼합되어 있다. 미세 도플러 영상에서 큰 피크가 8개 존재하는 것으로 보아 보행 속도에 따라 4초 동안 보행 사이클이 4번 반복된 것을 알 수 있다.

### III. 심층학습 신경망 모델

#### 3.1 AlexNet<sup>[9,10]</sup>

AlexNet은 2012년 개최된 ILSVRC (imagenet large scale visual recognition challenge) 대회의 우승을 차지한 컨볼루션 신경망 (convolution neural network; CNN) 구조이다. AlexNet의 기본 구조는 그림 7과 같이 5개의 컨볼루션 층과 3개의 완전 연결 (full-connected) 층인 8개의 계층으로 구성되어 있다. 활성화함수로는 ReLU (Rectified Linear Units)를 사용하며, 기존에 사용되던 Lenet-5의 tanh 함수보다 6배 이상 빠르게 수렴하는 효과를 얻을 수 있다. 컨볼루션 신경망 알고리즘들은 컨볼루션을 통해 얻은 특성맵의 크기를 줄이기 위해 풀링 (pooling)을 적용한다. AlexNet의 경우 최대값을 뽑아내는 최대 풀링 (max pooling)이 사용되었고, 풀링 커널이 움직이는 보폭인 stride를 커널 사이즈보다 작게 하는 겹침 풀링




그림 7. AlexNet 네트워크 구조<sup>[10]</sup>  
Fig. 7. Structure of AlexNet.

(overlapping pooling)을 적용했다. 그리고 과적합 (overfitting) 문제를 막기 위해 완전 연결 층의 뉴런 중 일부를 생략하는 드롭아웃 (dropout)과 데이터 증가법을 사용했다.

훈련 단계에서 적은 양의 데이터로 훈련시킬 경우 과적합 문제가 일어날 가능성이 크기 때문에 하나의 이미지를 가지고 좌우반전 등의 기법으로 여러 장의 비슷한 이미지를 만들어내 데이터의 양을 늘린다. 3개의 완전 연결 층 이후 뉴런의 출력 값에 소프트맥스 (softmax) 함수를 적용해 클래스 각각에 속할 확률을 구한다.

#### 3.2 VGGNet<sup>[11,12]</sup>

VGGNet은 옥스포드 대학의 VGG (visual geometry group) 팀이 개발한 모델로서, 컨볼루션 신경망의 깊이와 성능 간의 관계를 탐구하기 위한 목적을 가지고 있다. 깊이의 영향만을 최대한 확인하고자 컨볼루션 커널의 사이즈는 가장 작은 3 x 3으로 고정하였고, 모델의 성능을 효과적으로 향상시킬 수 있음을 증명하였다. 3개의 3 x 3 컨볼루션 층을 중첩하면 출력 층의 뉴런 하나에 영향을 미치는 입력 뉴런들의 공간 크기인 receptive field가 1개의 7 x 7 컨볼루션 층과 같아지지만, 활성화함수를 더 많이 사용할 수 있어서 더 많은 비선형성을 얻을 수 있으며, 파라미터 수도 줄어드는 효과를 얻을 수 있다. 또한, VGGNet은 스케일 지터링 방법을 사용하여 그림을 자르고, 훈련할 크기가 다른 이미지를 획득하여 모델의 견고성과 일반화 능력을 향상시켰다. 사전 훈련 된 방법을 사용하여 얇은 네트워크를 먼저 훈련시킨 다음 훈련된 매개 변수에 의해 심층 네트워크의 매개 변수를 초기화하여 수렴을 가속화한다. VGGNet의 네트워크 구조는 그림 8과 같다.





그림 8. VGGNet 네트워크 구조<sup>[12]</sup>  
Fig. 8. Structure of VGGNet.

3.3 GoogLeNet<sup>[13,14]</sup>

GoogLeNet은 2014년 ILSVRC 대회에서 우승을 한 신경망 구조이며, VGGNet보다 좀 더 깊은 22층으로 구성되어 있다. 이 신경망의 두드러진 특징은 네트워크의 깊이를 높이는 것뿐만 아니라 그림 9와 같이 인셉션 (inception) 모듈을 도입하여 네트워크의 폭을 넓히는 것이다. 기존에는 각 층 간에 하나의 컨볼루션 연산, 풀링 연산으로 연결하였다면, 인셉션 모듈은 총 4가지 서로 다른 연산을 거친 뒤 특징 맵을 채널 방향으로 합치는 방식을 이용한다. 다양한 수용 영역 (receptive field)을 표현하기 위해 1 x 1, 3 x 3, 5 x 5 컨볼루션 커널을 사용하여 이미지 정보를 처리하고 3 x 3 최대 풀링 해준 결과로 얻은 특성맵들을 모두 함께 쌓아준다. 1 x 1 컨볼루션은 특성맵의 개수를 줄이고 계산을 가속화하는 목적으로 사용되었다. 그리고 AlexNet, VGGNet 등에서는 완전 연결 층들이 신경망의 후반부에 연결되어 있는 반면, GoogLeNet은 완전 연결층 대신에 GAP (global average pooling) 방식을 사용한다. 이는 전 층에서 산출된 특성맵들을 각각 평균해 이어 붙여 1차원 벡터를 만들어주는 것이다. 1차원 벡터를 만들어주어야 최종적으로 이미지 분류를 위한 소프트맥스 층을 연결해줄 수 있기 때문이다. 이 단계를 통해 가중치의 개수를 상당히 많이 줄

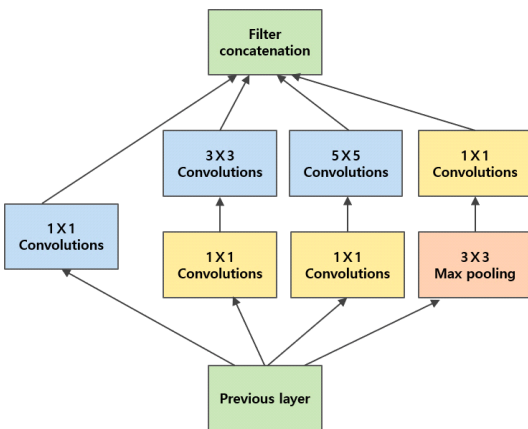


그림 9. GoogLeNet inception 모듈 모델<sup>[14]</sup>  
Fig. 9. Inception module model of GoogLeNet.

일 수 있다. 그러나 신경망의 깊이가 깊어질수록 신경망 내 가중치들이 제대로 훈련되지 않는 기울기 사라짐 (vanishing gradient) 문제가 발생한다. 이를 극복하기 위해서 GoogLeNet은 네트워크 중간에 두 개의 보조 분류기 (auxiliary classifier)를 사용한다. 보조 분류기의 구성은 5 x 5 평균 풀링 (stride 3) → 128개 컨볼루션 (1 x 1 커널) → 완전 연결 층 → 소프트맥스 층 순이며, 이 보조 분류기들은 훈련 시에만 사용되고 추론 단계에서는 제거해준다.

3.4 ResNet<sup>[15]</sup>

ResNet은 2015년 ILSVRC 대회에서 우승한 신경망이며, 지금도 널리 사용되는 구조이다. 이는 3 x 3 컨볼루션 층이 반복된다는 점에서 VGGNet과 유사한 구조를 가지고 있다. 계층의 수에 따라 ResNet-18, ResNet-34, ResNet-50, ResNet-101, ResNet-152 등 5가지 버전으로 나타낼 수 있으며, 계층의 수를 많이 사용할수록 연산량과 파라미터 개수는 커지지만 정확도도 좋아지는 효과를 얻을 수 있다. 네트워크의 구조는 그림 10과 같이 2 개의 컨볼루션 층에서 옆으로 화살표가 빠져나가 합쳐지는 식으로 구성되는 shortcut 을 사용한다.  $H(x)$ 는 특징 층의 원래 예상되는 출력이고  $x$ 는 입력이다. 기존 신경망들은  $H(x)$ 를 얻기 위한 학습을 했다면, ResNet은  $F(x)$ 가 0이 되는 방향으로 학습한다.  $F(x) = H(x) - x$ 이며,  $F(x)$ 를 학습한다는 것은 나머지 (residual)를 학습한다고 볼 수 있기 때문에 ResNet이라고 부른다. 따라서 이 구조는 심층 네트워크의 매개 변수 최적화의 어려움을 줄이고 저하 문제를 해결한다. 바로 가기 연결은 네트워크 복잡성을 줄이면서 인식 정확도를 향상시킬 수 있다.




그림 10. ResNet 네트워크 shortcut 구조<sup>[15]</sup>  
Fig. 10. Shortcut structure of ResNet.

#### IV. 모의실험 결과

본 장에서는 III장에서 설명한 4가지 심층학습 알고리즘을 이용하여 드론 블레이드, 조류, 보행자의 미세 도플러 표적 탐지 성능을 확인하는 모의실험을 진행한다.

##### 4.1 실험 환경 설정

모의실험에 사용한 드론, 조류, 사람의 데이터 세트<sup>[16-18]</sup>는 표적의 감지, 식별 및 추적에 사용하기 위해 수집된 신호이며, 사용한 드론과 조류 표적의 종류와 세부 사항은 표 1, 2와 같다. 보행자 표적은 나이, 성별, 신장 등의 다양한 특징을 가진 피실험자의 데이터를 이용하였다. 이 데이터 세트 중에서 70%를 훈련 데이터, 30%는 시험 단계 데이터로 분리하여 사용하였다.

표 1. 드론 실측 데이터베이스 세부 사항  
Table 1. Details of the drone databases.

Drone Type	Dimension (cm)	Range (m)
Bepop	38×33×3.6	50
AR	61×61×12.7	50
Phantom	52×49×29	50

표 2. 조류 실측 데이터베이스 세부 사항  
Table 2. Details of the bird flapping databases.

Bird Type	Flap angle (rad)	Velocity (m/s)
Chukar	2.5	1.2
Pigeon	1.57	1.5

##### 4.2 알고리즘 성능 평가 지표

혼동 행렬 (confusion matrix)은 분류 모델의 성능을 평가하는 데 사용되는  $N \times N$  행렬이다. 여기서  $N$ 은 대상 클래스의 수를 나타낸다. 이 행렬은 실제 목표 값과 기계 학습 모델에서 예측한 값을 비교한다. 이를 통해 분류 모델의 정확도와 오차에 대한 시각적인 지표를 제공한다. 그림 11은 다중 클래스 분류 문제의 혼동 행렬을 나타내며, 그림 안의 용어의 설명은 다음과 같다.

- TP (true positive) : 관심 범주를 정확하게 분류
- TN (true negative) : 관심 범주가 아닌 것을 정확하게 분류
- FP (false positive) : 관심 범주가 아닌 것을 관심 범주로 잘못 분류




그림 11. 다중 클래스 분류에서의 혼동 행렬  
Fig. 11. Confusion matrix for multi-class classification.

- FN (false negative) : 관심 범주를 관심 범주가 아닌 것으로 잘못 분류

이 4가지 정보를 바탕으로 정확도, 정밀도, 재현도와 같은 3가지 척도를 평가할 수 있다. 정확도 (accuracy)는 전체 데이터 중에서 올바르게 분류된 데이터의 비율로서 모델이 얼마나 정확하게 분류를 하는지를 나타낸다. 정밀도 (precision)는 올바르게 예측된 사례 중에서 실제로 관심 범주를 정확하게 분류한 수를 알려준다. 이 척도를 통해 모델이 신뢰할 수 있는지의 여부를 결정할 수 있다. 재현도 (recall)는 정밀도와 비교되는 척도로서, 실제 관심 범주 데이터 수에서 모델을 사용하여 관심 범주로 예측된 데이터의 수를 말한다. 3가지 척도는 식 (10), (11), (12)을 이용하여 계산할 수 있다.

$$\text{정확도 (accuracy)} = \frac{TP + TN}{TP + FP + TN + FN} \quad (10)$$

$$\text{정밀도 (precision)} = \frac{TP}{TP + FP} \quad (11)$$

$$\text{재현도 (recall)} = \frac{TP}{TP + FN} \quad (12)$$

##### 4.3 실험 결과 분석

1절의 실험 데이터 세트를 이용하여 세 표적을 분류하는 4가지 알고리즘의 성능을 비교 및 분석한다. 먼저 심층학습 알고리즘의 성능을 확인하기 위해 드론, 조류, 보행자를 분류하는 혼동행렬을 구하고, 식 (10), (11), (12)를 이용해 정확도, 정밀도, 재현도를

표 3. 드론 표적의 분류 성능 척도

Table 3. Classification performance evaluation of a drone target.

Learning algorithm	Accuracy (%)	Precision (%)	Recall (%)
AlexNet	86.89	79.79	81.25
VGGNet16	86.61	79.67	80.35
GoogLeNet	87.97	80.50	84.33
ResNet34	90.88	85.30	87.76

표 4. 조류 표적의 분류 성능 척도

Table 4. Classification performance evaluation of a bird target.

Learning algorithm	Accuracy (%)	Precision (%)	Recall (%)
AlexNet	85.93	79.29	78.21
VGGNet16	85.46	79.78	75.52
GoogLeNet	87.19	82.66	77.89
ResNet34	90.92	87.74	84.56

표 5. 보행자 표적의 분류 성능 척도

Table 5. Classification performance evaluation of a pedestrian target.

Learning algorithm	Accuracy (%)	Precision (%)	Recall (%)
AlexNet	89.32	84.14	83.74
VGGNet16	91.75	86.01	89.86
GoogLeNet	90.67	85.64	86.51
ResNet34	93.70	90.25	90.92

계산하였다. 각 표적을 분류하는 성능 척도는 표 3, 4 5에 나타내었다.

성능 척도표의 결과에서 각 표적 별 알고리즘의 평균 분류 성능을 볼 때, AlexNet은 정확도가 87.4%, 정밀도와 재현도가 81.1%이고, VGG-Net16은 정확도가 87.9%, 정밀도는 81.8%, 재현도는 81.9%이다. GoogLeNet의 경우, 정확도가 88.6%, 정밀도와 재현도가 82.9%이며, ResNet34는 정확도가 91.8%, 정밀도와 재현도는 87.8%의 성능을 가진다. 그림 12, 13, 14는 심층학습 분류 성능의 이해를 돕기 위해 분류 성능 척도를 그래프로 나타내었다.

세 가지의 표적을 분류할 때 4가지 알고리즘 모두 약 87% 이상의 우수한 분류 정확도 성능을 가지며, 그 중에서 ResNet34가 가장 효과적인 심층 학습 알고리즘임을 알 수 있다. 또한, 드론, 조류, 보행자 세 표적 중에서 보행자 표적이 다른 두 표적보다 정확도,

Performance of drone classification




그림 12. 드론 표적의 분류 성능 그래프  
Fig. 12. Classification performance of a drone target.

Performance of bird classification




그림 13. 조류 표적의 분류 성능 그래프  
Fig. 13. Classification performance of a bird target.

Performance of pedestrian classification

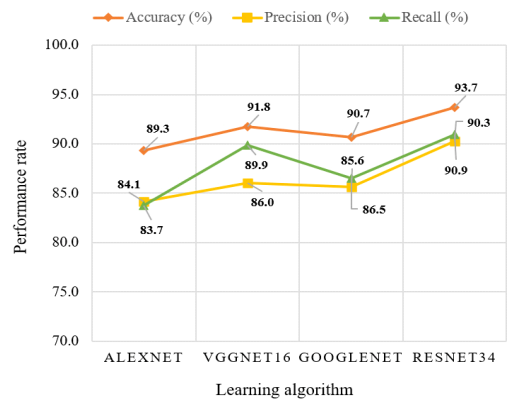


그림 14. 보행자 표적의 분류 성능 그래프  
Fig. 14. Classification performance of a pedestrian target.



정밀도, 재현도 측면에서 90% 이상의 성능으로 가장 분류가 잘 되는 것을 확인할 수 있다. 이는 드론과 조류 표적에 비해 몸 움직임에 따른 미세 도플러 신호가 많으며, 구별된 특징을 가지고 있기 때문에 심층학습을 통해 우수한 분류 성능을 얻을 수 있다.

각 표적의 미세 운동을 통해 II장 2절의 미세 도플러 영상을 얻고, 이를 심층학습 입력 데이터로 적용하면 각 표적을 효과적으로 분류할 수 있다.

## V. 결 론

본 논문에서는 서로 다른 미세 운동을 하는 드론, 조류, 보행자 표적을 분류하기 위해 미세 도플러 영상을 입력 데이터로 하여 심층학습 알고리즘을 적용하였다. 모의실험을 통해 심층학습 알고리즘을 이용한 각 표적의 분류 성능을 분석하였고, 4가지 알고리즘 모두 87%의 정확도를 얻을 수 있었다. 그 중 ResNet34는 정확도, 정밀도, 재현도 측면에서 90% 이상의 가장 우수한 성능을 가짐을 확인하였다. 향후 표적의 분별 정확도를 높이기 위해 표적 미세 도플러 특성벡터를 추출하는 연구를 수행할 예정이며, 표적 탐지 분야에 응용함으로써 관심 표적의 위치 및 속도 추정에서 더 높은 정확도를 얻을 수 있을 것으로 기대한다.

## References

[1] G.-H. Park, D.-G. Kim, H.-J. Kim, J.-O. Park, W.-J. Lee, J. H. Ko, and H.-N. Kim, "Performance analysis of interference cancelation algorithms for an FM Based PCL system," *J. KICS*, vol. 42, no. 4, pp. 819-830, Apr. 2017.

[2] S. Choi, D. Crouse, P. Willett, and S. Zhou, "Multistatic target tracking for passive radar in a DAB/DVB network: Initiation," *IEEE Trans. Aerospace and Electron. Syst.*, vol. 51, no. 3, pp. 2460-2469, Jul. 2015.

[3] F. Colone, T. Martelli, C. Bongioanni, D. Pastina, and P. Lombardo, "Wifi-based PCL for monitoring private airfields," *IEEE Trans. Aerospace and Electron. Syst.*, vol. 32, no. 2, pp. 22-29, Feb. 2017.

[4] H. Ma, M. Antoniou, D. Pastina, F. Santi, F. Pieralice, M. Bucciarelli, and M. Cherniakov,

"Maritime moving target indication using GNSS-Based bistatic radar," *IEEE Trans. Aerospace and Electron. Syst.*, vol. 54, no. 1, pp. 115-130, Feb. 2018.

- [5] V. Chen, "The Micro-Doppler Effect in Radar," Artech House, Norwood, MA, 2011.
- [6] V. Chen, D. Tahmoush, and W. Miceli, "Radar micro-doppler signatures - processing and applications," *IET Radar, Sonar and Navig. Series*, 34, 2014.
- [7] S. A. Musa, "Low-slow-small (LSS) target detection based on micro doppler analysis in forward scattering radar geometry," *Sensors*, vol. 19, no. 15, Jul. 2019.
- [8] F. Fioranelli, M. A. Ritchie, and H. Griffiths, "Multistatic human micro-doppler classification of armed/unarmed personnel," *IET Radar, Sonar & Navig.*, Mar. 2015.
- [9] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Advances in NIPS*, pp. 1097-1105, 2012.
- [10] X. Han, Y. Zhong, L. Cao, and L. Zhang, "Pre-Trained AlexNet architecture with pyramid pooling and supervision for high spatial resolution remote sensing image scene classification," *Remote Sensing*, vol. 9, no. 8, Jul. 2017.
- [11] X. Zhang, J. Zou, K. He, and J. Sun, "Accelerating very deep convolutional networks for classification and detection," *IEEE Trans. Pattern Anal. and Mach. Intell.*, vol. 38, no. 10, Oct. 2015.
- [12] U. Muhammad, W. Wang, S. Pervaiz Chattha, and S. Ali, "Pre-trained VGGNet architecture for remote-sensing image scene classification," *2018 24th ICPR*, pp. 1622-1627, Aug. 2018.
- [13] M. Lin, Q. Chen, and S. Yan, "Network in network," *arXiv preprint arXiv:1312.4400*, 2013.
- [14] C. Szegedy, W. Liu, Y. Jia, et al., "Going deeper with convolution," *IEEE Conf. CVPR*, pp. 1-9, Boston, M.A., USA, 2015.
- [15] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *2016*

*IEEE CVPR*, pp. 770- 778, Las Vegas, NV, USA, Jun. 2016.

- [16] M. F. Al-Sa'd, A. Al-Ali, A. Mohamed, T. Khattab, and A. Erbad "RF-based drone detection and identification using deep learning approaches: An initiative towards a large open source drone database," *Future Generation Comput. Syst.*, vol. 100, pp. 86-97, Nov. 2019.
- [17] T. A. Dececchi, Hans C. E. Larsson, and M. B. Habib, "The wings before the bird: An evaluation of flapping-based locomotory hypotheses in bird antecedents," *PeerJ*, Jul. 2016.
- [18] E. Gambi, G. Ciattaglia, A. D. Santis, and L. Senigagliaesi, "Millimeter wave radar data of people walking," *Data in Brief*, vol. 31, Aug. 2020.

**김 지 현 (Ji-Hyeon Kim)**



2017년 8월 : 부산대학교 전자공학과 학사 졸업  
 2019년 2월 : 부산대학교 전기전자컴퓨터공학과 석사 졸업  
 2019년 3월~현재 : 부산대학교 전기전자공학과 박사과정  
 <관심분야> 적응신호처리, 레이더 신호처리, 생체 신호처리

[ORCID:0000-0003-1425-2367]

**박 도 현 (Do-Hyun Park)**



2019년 2월 : 부산대학교 전자공학과 졸업  
 2019년 3월~현재 : 부산대학교 전기전자공학과 석박통합과정  
 <관심분야> 전자전·레이더 신호처리, 배열 신호처리

[ORCID:0000-0001-9885-1564]

**김 형 남 (Hyoung-Nam Kim)**



1993년 2월 : 포항공과대학교 전자전기공학과 학사 졸업  
 1995년 2월 : 포항공과대학교 전자전기공학과 석사 졸업  
 2000년 2월 : 포항공과대학교 전자전기공학과 박사 졸업  
 2000년 5월 : 포항공과대학교 전자컴퓨터공학부 박사후연구원

2000년 5월~2003년 2월 : 한국전자통신연구원 무선방송연구소 선임연구원  
 2003년 3월~2007년 2월 : 부산대학교 전자전기통신공학부 조교수  
 2007년 3월~2012년 2월 : 부산대학교 전자전기통신공학부 부교수  
 2009년 2월~2010년 2월 : Johns Hopkins Univ. Visiting Scholar  
 2015년 9월~2016년 8월 : Univ. of Southampton Visiting Professor  
 2012년~현재 : 부산대학교 전자공학과 교수  
 <관심분야> 적응신호처리, 레이더 및 소나 신호처리, 머신러닝, 생체 신호처리

[ORCID:0000-0003-3841-448X]