

# Machine Learning 기반 레이다 표적 식별 기술

김 영 옥

캘리포니아 주립대학교

## I. 서 론

Machine Learning은 인간이 원하는 작업을 컴퓨터 알고리즘으로 대체하기 위하여 Machine을 학습시키는 기술을 의미한다. 그 영역은 인간의 능력을 모방하는 수준을 넘어 사람보다 더 효율적으로 업무를 처리하는 것을 포함한다. Machine learning은 AI를 가능하게 하는 핵심 기술 중에 하나인데, 과거에는 Machine learning 기술이 적용될 수 있는 영역이 제한적이었다면 최근에는 그 발달로 공학, 의료, 경제 및 기초 과학 분야에까지 넓게 사용되고 있다. Machine learning을 이용할 경우, 다양한 업무 처리에 있어서 비용을 절감할 수 있고, 기존의 방식보다 뛰어난 성능을 기대할 수 있기 때문에 그 관심이 더욱 커지고 있다<sup>[1][2]</sup>.

Rosenblatt은 처음으로 1957년 Machine learning의 가장 기본적인 신호처리 단위인 Perceptron의 개념을 도입하고, Perceptron의 학습 방법을 제안했다<sup>[3]</sup>. Samuel은 Checker 게임에 Machine learning을 도입하였고, 그 개념을 정리하였다<sup>[4]</sup>. 1975년 Winston은 기계학습에 사용되는 알고리즘의 구조에 관한 연구를 하였다. 1980년대 중반이 되어서야 Artificial Neural Network (ANN)는 새로운 연구 분야의 하나로 자리를 잡게 된다<sup>[5]</sup>. 하지만 컴퓨터 성능의 한계로 학습에 있어서 속도가 느리고 Vanishing gradient problem 등의 문제로 인해 그 성능 및 응용의 한계를 맞이하게 되어 1990년대까지는 공학자들 사이에서 큰 관심을 받지 못하는 못하였다. 2000년대에는 Support Vector Machine (SVM)의 ANN보다 뛰어난 성능으로 각광을 받으며 널리 사용되기도 하였다<sup>[6]</sup>.

Machine learning 기술의 가장 큰 도약은 영상 인식 분야에서 일어났다. 2012년에 스탠퍼드대 Andrew Ng 교수는 16,000개의 컴퓨터로 약 10억 개 이상의 신경망으로 이뤄진 Deep Neural Network을 구현하였고, Youtube 이미지를 통해 사진을 높은 인식 확률을 가지고 분류 하는데 성공했다<sup>[7]</sup>. 그 이후 영상 인식분야의 성능은 매년 진화하는 Deep learning의

성능을 통해 비약적으로 발전하게 되었다<sup>[8]</sup>.

레이다 시스템에 있어서 표적 식별은 레이다의 중요한 기능 중에 하나이다. 레이다로 측정된 신호의 특징을 이용하여 표적을 식별하는 기술을 Non-Cooperative Target Recognition(NCTR) 또는 Automatic Target Recognition(ATR)이라 한다. 과거 NCTR 또는 ATR은 숙련자의 경험에 의존한 방식이 사용되었다. 하지만, 최근에 Machine learning 알고리즘의 발달로 식별 성능이 괄목하게 향상됨에 따라 최신 Machine learning 기술을 레이다에 적용해 보려는 연구가 시도되어 지고 있다. 따라서 Machine learning이 무엇이고, 레이다 분야에 어떻게 적용되어 왔으며, 앞으로 어떤 연구들이 가능한지 알아보는 일은 의미가 있다.

## II. Machine Learning의 기본

많은 공학자들은 자연 및 공학적 시스템을 수학 공식으로 모델링하고자 노력해 왔다. 시스템이란 주어진 입력에 대하여 출력을 발생시키는 장치로 간주될 수 있다. 시스템을 잘 기술하는 수학적 모델을 찾고 나면 그 시스템을 분석하고 예측하는 것이 가능해진다. 하지만 대부분의 경우에 있어서 시스템에 대한 명확한 물리적 정보가 제공되지 않기 때문에 이론적 방법을 통해 수학적 모델을 찾는 데에는 한계가 있다. 특히 식별문제에 있어서 간단한 수학 공식으로써 공학적 시스템을 설명할 수 없는 경우가 대부분이다. 만일 이론적 방법을 통한 수학적 모델링이 불가능할 경우에 사용될 수 있는 대체 수단이 바로 Machine learning 기법이다.

Machine learning 기술의 목적은 측정 혹은 시뮬레이션된 데이터를 기반 하여 입력과 출력의 관계를 수학적 함수로 기술하는데 있다. 여기서 말하는 Machine이란 다수의 매개변수를 포함한 수학적 모델을 의미한다. 그 모델의 매개변수들을 어떻게 결정하느냐에 따라 입출력의 관계가 달라진


다. 따라서 충분한 자유도를 가지는 범용 수학적 모델을 가정하고, 주어진 입출력 데이터를 잘 기술하도록 함수의 매개변수들을 결정하면 그것이 Machine learning의 결과물인 Data- Driven Model이 된다. 그리고 그 함수의 매개변수들을 결정하는 일을 학습이라고 말한다. 이 결정된 수학적 모델은 새로운 입력에 대해 출력 값을 추정할 수 있기 때문에 Data- Driven Model을 통하여 시스템을 예측할 수도 있다. 하지만 엄밀히 말하자면 이는 예측이 아니라 회귀(regression)라는 표현이 더욱 정확할 것이다. 왜냐하면 기존 Database에 존재하지 않는 입력 영역에 대한 외삽법(extrapolation)은 출력의 정확도가 떨어지기 때문이다.

Machine learning에는 ANN, SVM, Multivariate Adaptive Regression Splines (MARS) 등이 있는데, ANN이 가장 보편적으로 사용되어 왔다. ANN의 구조는 인간의 뇌의 구성요소인 뉴런의 연결 방식을 모방하여 설계되었다. ANN은 Multi-layer로 되어 있으며, 각 Layer는 여러 개의 Perceptron으로 구성되어 인간의 뇌를 모방하였다. 수상돌기에서 축색돌기로 신호를 전달하고 뉴런과 뉴런사이에는 시냅스가 존재하듯 ANN에서는 수신 신호의 가중치가 곱해진 값이 다음 Layer에 전달되고, Activation function을 통과된 후의 값이 새로운 출력이 되는 구조를 [그림 1(a)]와 같이 가지고 있다. ANN의 전체 구조는 [그림 1(b)]에 보여 졌다. 각 노드는 Perceptron이라고 불리 우며, Perceptron에 관한 값은 다음과 같은 수식으로 계산이 가능하다<sup>[1]</sup>.


$$o_j = \varphi(net_j) = \varphi\left(\sum_{k=1}^n w_{kj}o_k\right) \quad (1)$$

여기서  $\varphi$ 는 Activation Function이라고 불리 우는 비선형 함수로 입력과 출력 사이를 비선형적 근사를 가능하게 한다. 이론적으로는 ANN 구조에서 충분한 Perceptron을 가지고 있다면 단일 Layer 만으로도 어떤 연속 함수든지 수학적 근사화가 가능하다고 알려져 있다.

ANN의 학습이란 Perceptron 사이를 연결하는 가중치(weight) 값들을 최적화 하는 일이다. ANN의 크기에 따라 가중치의 개수가 수천에서 수백만에 이르기 때문에, 이들의 추정에 필요한 계산량은 매우 많다. 따라서 현실적으로 가



(a) ANN의 기본 구조인 Perceptron의 연결



(b) ANN의 전체 구조

[그림 1] ANN의 구조

능한 시간 내에 이 가중치 값들을 최적화 하는 것이 필요하다. 가중치의 최적화를 위해서는 이상적으로는 Global optimizer가 사용되어야 하지만, 실제로는 Conjugate gradient 나 Levenberg Marquardt와 같은 Local optimizer 방법 등이 개발되어 사용되고 있다. Multi-layer에서 사용 가능한 Back-propagation 알고리즘이 개발되어 Gradient를 계산하는데 사용된다. 특정 가중치  $w_{ij}$ 에 대한 최종 오차 ( $E$ )의 변화는 다음의 식으로 계산이 가능하다<sup>[2]</sup>.

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial net_j} \frac{\partial net_j}{\partial w_{ij}} \quad (2)$$

Machine Learning의 성능을 평가하는 방법 중에 가장 중요한 기준 중에 하나는 Generalization 이다. 즉, 주어진 데이터를 가지고 얼마나 그 속성을 일반화 하였는가 하는 것이다. 만일 학습된 ANN이 일반화가 잘 되었다면 새로운 입력 데이터에 관하여서도 작은 오차의 출력 값을 발생시키지만, 반대로 일반화가 되지 않은 ANN은 새로운 데이터에 관하여 올바른 출력 값을 도출하지 못한다. 일반화를 위해서는 주어진 데이터를 고려하여 Overfitting이 되지 않게 ANN 크기 및 구조를 결정해야 한다.

### III. Deep Learning

소수의 엔지니어들만이 알고 있던 Deep learning 분야는 2016년 알파고의 바둑 이벤트를 통해 대중적 관심이 받게 되었으며, 최근 Deep learning을 이용한 사례들이 빠른 속도로 늘어나고 있다. Deep learning은 Machine learning의 부분 집합으로써 하나의 세부 방법론으로 볼 수 있다. 기존의 Machine learning은 단일 혹은 소수의 Hidden layer를 이용해 왔다. 왜냐하면 Hidden layer가 많아지면 Back-propagation의 성능이 떨어지고, 최적화해야 하는 매개변수들이 많아져서 그 만큼 학습에 필요한 계산량이 많아지기 때문이다. 그 만큼 학습의 성공 확률이 낮아진다. 과거에는 제한된 계산 능력으로 방대한 ANN을 학습시킬 수 없었기 때문에 Deep layer의 개념은 제안되었지만, 성공적으로 구현되지는 못했다. 하지만 최근에는 병렬처리가 가능한 GPU의 발달과 ReLU와 같은 새로운 Activation function 및 효과적인 최적화 방법을 통하여 Multi-layer의 학습이 성공적이 되었다. Multi-layer를 사용하면 처리되지 않은 원시 데이터로부터 Feature extraction과 식별 등 여러 신호 처리 과정을 한 번에 해결할 수 있는 장점이 있다. 반면, Deep learning의 단점은 이를 성공적으로 사용하려면 방대한 양의 데이터가 필요하고, ANN의 구조가 복잡하여 학습에 시간이 오래 소요된다. 또한, 최종 학습된 Net도 그 구조가 방대하여 새로운 입력 값에 대해서도 출력값을 도출하는데 일반적인 PC로는 실시간 처리가 어렵다는 문제점이 있다.

### IV. Deep Learning을 이용한 레이더 표적 인식의 응용

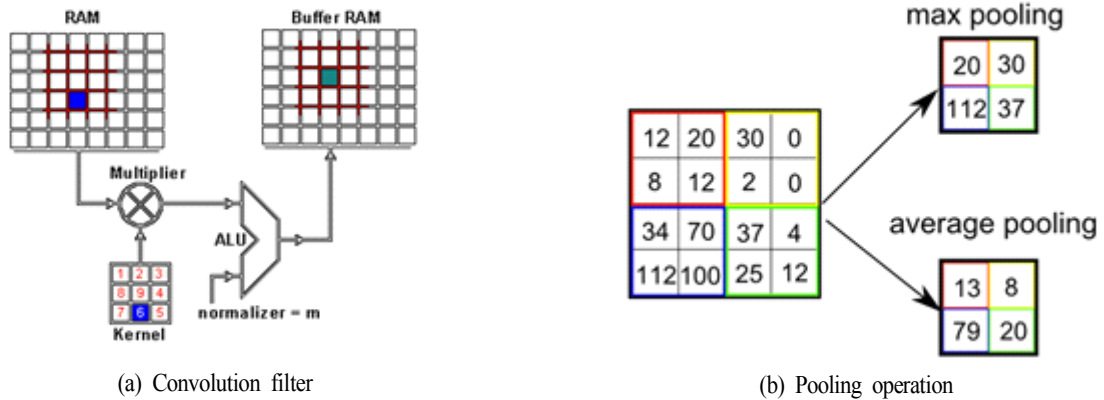
레이더 표적 인식은 레이더 운용의 고전적인 분야의 하나로 탐지된 신호의 특성을 분석하여 표적을 분류하는 작업이다. 현재까지 레이더 표적 식별은 크게 두 가지로 나뉘고 볼 수 있다. 첫 번째는 레이더에서 Range profile 상에서 탐지된 개별 표적의 종류를 구분하는 것이고, 두 번째는 Synthetic Aperture Radar (SAR)에서 얻은 2차원 이미지로부터 특정 관심 표적을 식별하는 것이다. Deep learning을 이용한 식별은 2차원 이미지에서 매우 성공적으로 동작했기 때문에 레이더의 출력을 이미지화 할 수 있다면 Deep learning을 이용한 영상처리 방법을 적용할 수 있다.

첫 번째 응용의 경우에 있어 기존에는 표적의 속도, 길이, RCS, micro-Doppler 등의 특성을 기반으로 분류기를 사용하여 표적을 식별하는 일이다. 특히 최근에는 표적의 미세 운동에 의해 발생하는 micro-Doppler에 대한 연구가 많이 이루어 졌다. 표적의 속도 길이 RCS와 같은 기본적인 1차원 정보만으로는 표적을 구분하기가 쉽지 않다. 때문에 표적의 이동 중에 회전, 진동 혹은 Non-rigid body의 움직임에 의해 발생하는 micro-Doppler를 관찰하면 표적에 대한 더 많은 정보를 얻을 수 있다. Micro-Doppler는 시간에 따라 변화하는 주파수 성분이기 때문에 Joint-Time Frequency Analysis를 통하여 그 특성을 관찰할 수 있다. Short-Time Fourier Transform이 주로 사용되나, Wigner-ville Distribution과 같은 고해상도 방법을 이용해서도 micro-Doppler 특성을 2차원 흑백 이미지로 시각화 할 수 있다. micro-Doppler 이미지가 시각화 되면 그 이미지의 특성을 추출하여 그것을 표적의 분류에 사용하게 된다<sup>[9]</sup>. 최근에는 영상인식에 사용되었던 Convolutional Neural Network (CNN)를 이용하여 표적 식별 문제를 접근하는 방법이 연구되고 있다.

CNN은 Convolution filter와 Pooling이 결합된 Layer가 다 층으로 구성되고, 그 후에 Fully connected layer를 연결하여 영상을 인식 하는 구조를 가지고 있다. 그 Layer 수가 많은 CNN 구조를 Deep Convolutional Neural Network (DCNN)이라 부른다. Convolution filter는 원래 이미지의 부분과의 내적을 통하여 그 이미지의 특징을 [그림 2(a)]와 같이 추출한다. Pooling layer에서는 데이터의 차원을 [그림 2(b)]와 같이 줄임으로써 처리를 용이하게 한다. Overfitting을 방지하기 위해서 Dropout와 같은 방식을 사용하기도 한다.

Convolution filter의 갯수와 크기 및 Layer의 수는 경험적으로 결정되어지고, Filter의 값 및 특성 등은 주어진 데이터의 학습을 통해 결정되어 진다. 일반적인 경우에 있어서 대략 80 % 데이터를 학습에 사용하고, 나머지 20 %의 데이터를 검증 및 테스트에 사용하게 된다.

DCNN을 이용하여 micro-Doppler를 바탕으로 레이더 표적을 구분하는 연구는 최근에 다양하게 진행되어 왔다. 사람의 행동을 인식하는 문제, 손동작 인식, 드론 인식 등이 대표적인 예이다. DCNN이 처음 micro-Doppler에 이용된 것은 레이더로 측정된 사람의 동작을 식별하는 문제였다<sup>[10]</sup>.




[그림 2] Convolutional layer

레이다로 사람의 동작을 인식하게 되면 전자파의 벽투과 특성을 통해 건물 안의 사람들의 행동을 감시할 수 있을 뿐만 아니라, 화재 시 시야가 확보되지 못한 상황에서 사람들을 모니터링할 수 있다. 또한, 일상생활에서는 침입 감시 시스템이 이용될 수 있으며, 의료 분야에 있어서는 낙상과 같은 사고를 판단할 수 있다. 2.4 GHz로 CW로 측정된 7가지 사람의 행동들은 서로 다른 micro-Doppler 특성을 보였고, 그 예는 [그림 3]에 보여졌다.


Spectrogram에서 나타나는 micro-Doppler의 특징을 추출한 후 SVM을 이용하여 식별을 할 수 있지만, DCNN을 이용

한 방법에서는 특징 추출 과정 없이 전 과정을 자동화 할 수 있는 장점이 있다. [그림 4]에 보여진 바와 같이 3개의 Convolutional layer가 사용되었고, 필터 수는 20개이고, 필터 크기는 5x5일 때 정확도는 90.3 %였다. 이 테스트에는 1,008 개의 이미지가 사용되었다. 이 연구에서는 DCNN의 적용 가능성은 보여 졌지만, 그 데이터의 수가 상대적으로 적은 문제가 있었다.

레이다를 이용한 손동작 인식에 관한 연구에서도 DCNN이 사용되었다<sup>[11]</sup>. 만일 손동작이 소형 레이다로 인식될 수 있다면 컴퓨터와 사람 사이의 인터페이스의 한 방법으로써



[그림 3] 서로 다른 micro-Doppler 특징의 예




[그림 4] Micro-Doppler의 식별 DCNN의 구조

중요한 역할을 할 수 있다. 레이더를 이용할 경우, 광학 카메라보다 사생활 침해 부분에 있어 더욱 자유로울 수 있다. 7가지 손동작을 5.8 GHz에서 동작하는 Doppler 레이더로 측정하고, 스펙트로그램을 구해 보면 [그림 5]와 같다. 이를 DCNN으로 구분하기 위해 3층의 Convolutional layer를 이용하여 식별을 한다. 필터 수는 5이고, 필터 크기는 5×5일 때 정확도는 93 %였다.


또한 드론의 탐지 및 특성을 구분하는 데에도 DCNN이 이용되었다<sup>[12]</sup>. 드론의 회전 날개로부터 주기적인 micro-Doppler 특성이 나오는데, 이를 이용하여 모터의 수와 드론의 특성을 구분할 수 있다. Spectrogram에서는 시간에 따라 변화하는 micro-Doppler 특성은 보여 지지만, micro-Doppler의 주기적인 특성은 따로 표현되지 않는다. 따라서 micro-Doppler 주기성을 이용하기 위해 Spectrogram의 각 행을 Fourier Transform하여 Cadence-Velocity Diagram(CVD)을 생성해 낼 수 있다. Micro-Doppler Spectrogram(MDS)과 CVD를 합친 이미지

를 DCNN에 적용하여 드론을 분류하는 방법이 제안되었다. Ku-band 레이더를 이용하여 측정한 드론의 예는 아래 [그림 6]과 같다. 두 이미지가 합쳐진 이미지를 DCNN에 이용한 결과, 94 %의 정확도를 가지고 드론의 특성을 판단할 수 있었다.

또, 다른 레이더 표적 식별의 대표적인 분야는 SAR 이미지 분류이다. SAR를 통하여 지형 및 지표의 건축물들을 이미지화 할 수 있고, 이를 바탕으로 표적을 인식하는 것은 군사 및 지구 과학적으로 매우 중요하다. SAR 이미지를 이용한 ATR은 3단계, 즉 Detection, Discrimination과 Classification으로 이루어져 있는데, Classification 단계에서 표적을 식별한다. SAR 이미지의 표적은 광학 이미지와는 다르게 Signal to noise ratio(SNR)이 낮고, 사물의 형태가 왜곡되어 나타나기 때문에 일반적으로 육안을 통해 표적을 식별하기 힘든 문제점이 있다. 과거에는 Template matching을 이용한 방법으로 표적을 식별하였다면 최근 DCNN을 통하여 이를 해결



[그림 5] 손동작에 의한 micro-Doppler의 예



[그림 6] 드론의 로터 회전 방향에 따른 micro-Doppler와 CVD의 예<sup>[12]</sup>

하려는 연구가 최근에 다양하게 진행되었다.

2016년 Zhao 등은 이 분야의 기초 연구로서 TerraSAR-X 로 측정된 [그림 7]과 같은 5종류의 SAR Image patch를 이용하여 DCNN으로 학습시켰다. 제안된 DCNN은 2개의 Convolutional layer와 Fully connected layer 등을 포함한 총 7 Layer로 구성되어 있었고 Caffe 틀을 이용한 결과 85.6 % 이상의 정확도를 가지고 표적을 식별할 수 있었다<sup>[13]</sup>. 이것은 기존의 Feature extraction과 SVM을 사용한 결과보다 향상된 결과였다.


하지만 SAR 이미지를 DCNN으로 학습시키는 데에는 Overfitting 문제가 존재한다. 왜냐하면 사용 가능한 SAR 이미지의 데이터 수보다 DCNN이 모델의 자유도가 훨씬 높기 때문이다. 이를 극복하기 위하여 Chen 등은 소수의 Weight만이 연결되어 있는 새로운 All-convolutional networks (A-ConvNets)를 제안하였다<sup>[14]</sup>. [그림 8]과 같이 이동 표적 인식 문제에 있어서 99 %의 식별 정확도를 가질 수 있음을

확인하였다.


최근에는 SAR 이미지 처리의 3단계를 모두 담당하는 하나의 DCNN을 이용하여 SAR 이미지로 부터 표적을 식별하는 연구가 진행되고 있다<sup>[15]</sup>.

### V. Deep Learning을 이용한 레이다 영상처리의 문제점

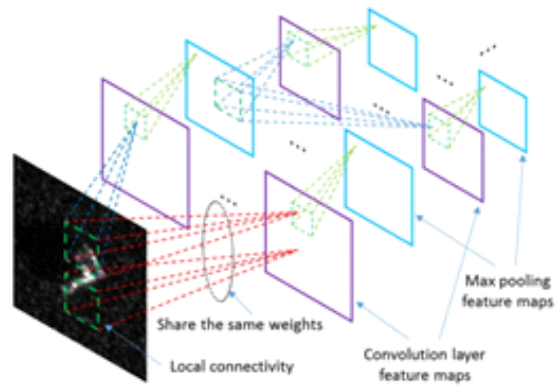
위의 예에서 보여 지듯이 DCNN을 이용하면 기존의 특징 추출을 통한 식별 방법보다 높은 정확도의 식별 성능을 획득할 수 있다. 하지만 레이다 영상의 경우, 기존의 광학 카메라 이미지와는 다르게 그 샘플 수가 적은 문제가 존재한다. 광학 이미지의 경우, 카메라를 통해 이미지들을 상대적으로 쉽게 생성해 낼 수 있고, 뿐만 아니라, 인터넷상에서도 충분히 서로 다른 수백만 개의 샘플을 획득하는 것이 용이하다. 하지만 레이다 이미지의 경우는 대부분 측정을 통하여 얻어



[그림 7] CNN으로 구분된 5가지 종류의 SAR patch 이미지<sup>[13]</sup>



(a) 10개 종류의 SAR 표적



(b) DCNN을 이용한 처리

[그림 8] SAR 이미지 표적의 인식 과정<sup>[14]</sup>

지는데, 그 측정에서는 시간적 금전적 비용이 많이 발생한다. 따라서 현실적으로 획득 가능한 이미지의 수는 대부분의 경우 수백 장에서 천장에 불과하다. 딥러닝의 모델과 같이 많은 양의 매개변수를 추정하기 위해서는 그에 상응하는 데이터의 수가 필요하지만, 적은 데이터 개수 때문에 진정한 의미에서의 딥러닝 기법을 구현하는 데에는 한계가 있다.

이를 극복하기 위해 제안되는 방법에는 세 가지가 있다. 첫 번째는 시뮬레이션을 통하여 레이다 이미지를 생성해 내는 방법이다. 레이다 이미지 중 대표적인 마이크로 도플러 이미지나 SAR 이미지는 시뮬레이션을 통하여 생성이 가능하다<sup>[16][17]</sup>. 시뮬레이션을 통하여 방대한 양의 이미지를 형성해 내고, 이를 바탕으로 Machine을 학습시킬 수 있다. 두 번째 방법은 Transfer learning을 이용한 방법이다<sup>[18]~[20]</sup>. 레이다 이미지가 아니라 광학 이미지를 이용하여 DCNN을 학습시키고, 그 학습된 모델을 가져와서 레이다 이미지 식별에 적용하는 방식이다. 세 번째는 Generative Adversarial Networks (GANs)를 이용한 방법이다<sup>[21]</sup>. 실제 레이다 이미지를 바탕으로 유사 레이다 이미지를 만드는 Machine을 생성해 내고 원하는 만큼의 이미지를 발생시키는 방법이다. 첫 번째 방법인 시뮬레이션을 이용한 방법은 표적의 다양한 상황을 시뮬레이션 하는 것이 쉽지 않을 경우가 있고, 그에 따라 시뮬레이터를 따로 만들어야 하는 번거로움이 있다. 따라서 여기에서는 문제에 특정화되지 않고 일반적으로 사용될 수 있는 Transfer learning과 GANs를 이용한 방법에 관하여 알아본다.

### 5.1 Transfer Learning

Transfer learning은 어떤 한 데이터 셋을 이용하여 Net을 학습시키고 성공적으로 학습된 그 Net을 그대로 가져와서 새로운 데이터 셋에 적용하는 방법이다. 만일 두 데이터 셋 사이에 유사성이 존재하거나, 한 쪽 데이터 셋에서 사용된 특징 추출 방법이 다른 데이터 셋에서도 동작을 한다면 Transfer learning은 효과적으로 사용될 수 있다. Transfer learning에서는 입력 Layer와 출력 Layer 그리고 출력에 연결되는 마지막 Fully connected layer는 새로 설계해야 하지만, 이를 제외한 Net은 이미 학습된 것을 사용한다. 따라서 새로운 데이터로는 마지막 Fully connected layer만을 학습하면


되기 때문에 학습시간도 적게 소요된다.

적은 수의 레이다 이미지로 분류기의 성능을 향상시키기 위해서는 광학 이미지들로 학습된 Net들을 사용할 수 있다. 매년 ImageNet Large Scale Visual Recognition Challenge (ILSVRC)에서는 1,000가지 종류가 되는 150만 개의 이미지가 구비되어 있는 ImageNet을 분류하는 문제를 어느 알고리즘이 가장 성공률이 높은지 경쟁한다. [그림 9]에서 보여지는 바와 같이 매년 그 성능이 향상되어 2015년의 ResNet은 사람보다 더 정확한 성능으로 이미지를 분류할 수 있었다. ImageNet으로 학습된 일부 Net들은 인터넷상에 공개되어 사용 가능하기 때문에, 이 모델들을 레이다 이미지에 적용해 보는 일은 흥미로운 일이다. 특히 AlexNet과 VGG-16이 쉽게 사용 가능하여 주로 Transfer learning에 이용되고 있다.

실제로 수 백장의 레이다 이미지만을 이용해 DCNN을 학습시킨 결과와 Transfer Learning을 한 결과를 살펴보면 그 성능이 향상됨을 알 수 있다<sup>[9]</sup>. 특히 AlexNet 보다 그 구조가 한층 Deep하고, 복잡한 VGG-16의 성능이 더욱 좋음을 확인할 수 있다.

### 5.2 GANs를 이용한 학습데이터 생성

Generative Adversarial Networks (GANs)는 2014년 Goodfellow 박사가 제안한 모델로 최근 10년간 가장 혁신적인 모델로 평가 받고 있다. GANs의 목적은 그림이나 시와 같은 사람의 창작물 및 인간의 행동 등을 모방하는 모델을 만드는 것이다. 이를 위해 GANs는 Generative Network과 Discriminative Network로 구성되며, Supervised-learning을 통해 이 두 Net이 서로 학습되는 구조를 가지고 있다. 이 구조를 통하여 특정 분포를 가지는 데이터를 임의로 만들 수 있고, 이를 레이다 이미지에 적용하면 레이다 이미지와 유사한 결과



[그림 9] 다양한 ANN을 이용한 ImageNet의 식별 성능

를 만들어낼 수 있다.

Generative network은 Random noise로 부터 입력을 받아 새로운 이미지를 형성해 내는 역할을 한다. 반면, Discriminator는 전형적인 분류기로 입력된 이미지가 진짜 이미지인지, 가짜 이미지인지를 판단한다. GANs에서는 Discriminative network은 최대한 정확한 판단을 하도록 유도하고, Generative network은 최대한 Discriminative network의 판단의 정확도가 낮아지도록 유도한다. Generative network에서 생성된 이미지가 Discriminative network에서 분류 정확도가 떨어진다 것은 생성된 가짜 이미지가 진짜 이미지와 유사하다는 것을 뜻하게 된다. GANs의 일반적인 구조는 [그림 10]과 같다.

이는 GANs에서는 Discriminative network과 Generative network을 번갈아 학습하면서 다음의  $V$ 를 최대화 하는 것을 목적으로 한다.  $V$ 가 높은 값을 가질수록 Generative network이 성능은 향상된다.

$$V(D, G) = E_{x \sim P_{data}(x)}[\log D(x)] + E_{z \sim p(z)}[1 - \log D(G(z))] \quad (3)$$

여기서  $x$ 는 실제 이미지에서 나온 샘플이고,  $z$ 는 Generative Network의 입력 값,  $G(z)$ 는 Generative network의 출력 그리고  $D$ 는 Discriminative network의 분류 정확도가 된다. 대부분의 경우에 있어 수백 번 이상의 반복을 통하여 학습이 되며, 수십 시간 이상의 시간이 소요되게 된다. 하지만 일단 GANs가 학습이 되고 나면 새로운 이미지를 생성하는 데에는 최소한의 시간만이 필요하게 된다. 따라서 GANs를 이용하여 충분한 레이다 이미지를 생성해 내고, 이들을 이용하여 DCNN을 학습시키는 것은 하나의 효과적인 방법일 수 있다. 초기 연구로서 실제 GANs를 이용하여 생성된 micro-Doppler 이미지의 예는 다음과 같다. 아직 이 분야는 연구가


충분히 되어 있지 않기 때문에, 앞으로 다양한 연구가 필요하다.

## VI. 결 론

Machine learning의 발달은 레이다 이미지 식별 분야의 새로운 방법론을 제시하였고, micro-Doppler와 SAR 분야에서 그 성능이 검증되고 있다. 특히 DCNN의 레이다 이미지에 대한 응용이 괄목할 만한 결과들을 내고 있다. 또한, Machine learning 분야에서 개발된 새로운 알고리즘은 레이다 신호 처리에도 적용되어 기존에 한계들을 조금씩 극복해 나가고 있다. 특히 GANs와 같은 새로운 모델들의 레이다 이미지에 대한 적용은 학습 데이터 생성 및 de-noising 등의 분야에 더욱 활발하게 응용되어질 수 있다. 기존의 군사용 레이다 뿐만 아니라, 특히 차량용 레이다에는 다양한 상황에서 다양한 사물을 처리 및 인식하는 Machine learning이 적용되어야 하기 때문에 앞으로 연구되어야 하는 주제들이 많이 있다. 하지만 Machine learning이 실용화되기 위해서는 실시간 처리를 위한 고속 CPU 및 GPU의 개발과 학습된 Net을 최적화 하여 계산량을 축소시키는 문제 등이 해결되어야 할 것이다.

## 참 고 문 헌

- [1] J. Friedman, R. Tibshirani, and T. Hastie, *The Elements of Statistical Learning*, Springer, 2001.
- [2] C. Bishop, *Pattern Recognition and Machine Learning*, Springer, 2006.
- [3] F. Rosenblatt, "The perceptron—a perceiving and recognizing automaton," *Report 85-460-1*, Cornell Aeronautical Laboratory, 1957.
- [4] A. Samuel, "Some studies in machine learning using the game of checkers," *IBM Journal of Research and Development*, 1959.
- [5] P. Winston, "Learning structural descriptions from examples", *The Psychology of Computer Vision*, Chapter 5. McGraw Hill, 1975.
- [6] C. Cortes, V. Vapnik, "Support-vector networks", *Machine*



[그림 10] GANs의 구조(Image from <https://deeplearning4j.org>)



- Learning*, Vol. 20, pp. 273-297, 1995.
- [7] A. Ng, J. Dean, "Building high-level features using large scale unsupervised learning", arXiv:1112.6209, 2012.
- [8] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, pp. 436-444, May 2015.
- [9] Y. Kim, H. Ling, "Human activity classification based on micro-Doppler signatures using a support vector machine," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, pp. 1328-1337, May 2009.
- [10] Y. Kim, T. Moon, "Human detection and activity classification based on micro-Dopplers using deep convolutional neural networks," *IEEE Geoscience and Remote Sensing Letters*, vol. 13, pp. 2-8, Jan. 2016.
- [11] Y. Kim, B. Toomajian, "Hand gesture recognition using micro-Doppler signatures with convolutional neural network," *IEEE Access*, vol. 4, pp. 7125-7130, Oct. 2016.
- [12] B. Kim, H. Kang, and S. Park, "Drone classification using convolutional neural networks with merged Doppler images," *IEEE Geoscience and Remote Sensing*, vol. 14, pp. 38-42, Nov. 2016.
- [13] J. Zhao, W. Guo, S. Cui, Z. Zhang, and W. Yu, "Convolutional neural network for SAR image classification at patch level," *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2016.
- [14] S. Chen, H. Wang, F. Xu, and Y. Jin, "Target classification using the deep convolutional networks for SAR Images," *IEEE Trans Geoscience and Remote Sensing*, vol. 54, pp. 4806-4817, 2016.
- [15] H. Furukawa, "Deep learning for end-to-end automatic target recognition," *IEICE Technical Report*, vol. 117, arXiv:1801.08558, 2018.
- [16] S. Ram, C. Christianson, Y. Kim, and H. Ling, "Simulation and analysis of human micro-Dopplers in through-wall environments," *IEEE Trans. Geoscience and Remote Sensing*, vol. 48, pp. 2015-2023, 2010.
- [17] C. Liang, Y. Li, D. Lu, J. Li, and L. Yan, "Simulation and analysis of micro-Doppler signatures of tracked vehicles," *IET International Radar Conference*, Oct. 2013.
- [18] J. Park, J. Rios, T. Moon, and Y. Kim, "Micro-Doppler based classification of human activities on water via transfer learning of convolutional neural networks," *Sensors*, vol. 16, pp. 1990, Nov. 2016.
- [19] I. Alnujaim, H. Alali, F. Khan, and Y. Kim, "Hand gesture recognition using input impedance variation of two antennas with transfer learning," *IEEE Sensors Journal*, vol. 18, pp. 4129-4135, May 2018.
- [20] Z. Huang, Z. Pan, and B. Lei, "Transfer learning with deep convolutional neural network for SAR target classification with limited labeled data," *Remote Sensing*, vol. 9, 2017.
- [21] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, "Generative adversarial networks," arXiv:1406.2661, 2014.

≡ 필자소개 ≡

김 영 욱



계학습 알고리즘

2003년 서울대학교 (공학사)

2005년 University of Texas at Austin (공학석사)

2008년 University of Texas at Austin (공학박사)

2008년 California State University, Fresno 조교수

2014년 California State University, Fresno 부교수

2018년 California State University, Fresno 교수

[주 관심분야] 레이더 신호 처리, 안테나 최적화, 기