

# 사전훈련된 딥러닝 네트워크를 활용한 이미지 기반 딥러닝 모델 설계

김승환\*, 문창배\*, 권기협\*, 김동성<sup>o</sup>

## Design of the Image-Based Deep Learning Model Using a Pre-Training Deep Learning Network

Seung-Hwan Kim\*, Chang-Bae Moon\*, Ki-Hyeob Kwon\*, Dong-Seong Kim<sup>o</sup>

### 요 약

본 논문에서는 인지 통신에 사용되는 자동 변조 분류를 위해 이미지 기반 딥러닝 모델을 설계하였다. 제안된 설계 방식은 초기 신호 기반 딥러닝 모델과 이미지 기반 딥러닝 모델 2가지로 구분되며 딥러닝 네트워크 유형은 Convolutional Neural Network (CNN)을 사용하였다. 신호 기반 딥러닝 모델 프레임 단위로 학습되도록 하였고 각 프레임은 1024 신호 샘플로 구성하였다. 학습전 Root Mean Square (RMS) 방식을 통해 프레임을 정규화하였고 실수부와 허수부로 구분하여  $2 \times 1024$  크기로 입력하였다. 제안된 신호 기반 딥러닝 모델은 컨볼루션 레이어의 필터 크기에 따른 정확도 성능에 대하여 분석한 다음  $1 \times 8$  필터 크기 지정을 통해 예측성능을 최적화하였다. 이미지 기반 딥러닝 모델은 사전훈련된 신호 기반 딥러닝 네트워크를 사용하여 추출된 특징 데이터를 이미지로 변환하여 학습된 다음 각각의 변조 유형을 예측하도록 하였다. 추출된 특징은 신호 기반 딥러닝 네트워크의 Fully-Connected layer를 통해  $24 \times 1$  특징 크기로 추출하였으며 각 특징이 가지는 특징값은  $-30 - +30$  스케일 범위에 따라 Red, Green, Blue (RGB) 이미지로 변환하였다. 제안된 모델의 예측 정확도 성능은 Signal-to-Noise Ratio (SNR) 10 dB에서 기존 ECNN, SCGNet 그리고 LCNN 보다 1.38%, 7.41% 그리고 4.05% 높은 예측 정확도를 보였으며 SNR 0 dB에서는 0.26%, 3.4% 그리고 1.13% 각각 높은 성능을 보였다.

**Key Words** : Automatic Modulation Classification, Convolutional Neural Network, Cognitive Radio Networks, Predicted Accuracy, Computational Complexity

### ABSTRACT

In this paper, an image-based deep learning model is designed for Automatic Modulation Classification (AMC) in cognitive radio. The proposed design method consists of a signal-based deep learning model and an image-based deep learning model, and a Convolutional Neural Network (CNN) is used for the deep learning network type. The signal-based deep learning model is trained in units of a frame which is composed of 1024 signal samples. Before being used for training, the frame is normalized through the Root Mean Square (RMS) method, and the frame is divided into the real part and the imaginary part. The proposed signal-based deep learning model is analyzed according to the filter size of the convolution layer and optimized by specifying

※ 본 연구는 금오공과대학교 학술연구비로 지원되었음(2019104131).

• First Author : SK Siltron, DT strategy team, seunghwan.kim3@sk.com, 정희원

o Corresponding Author : Kumoh National Institute of Technology, IT Convergence Engineering, dskim@kumoh.ac.kr, 종신회원

\* Kumoh National Institute of Technology, ICT Convergence Research Center, cb.moon@kumoh.ac.kr, 정희원; navkwon@kumoh.ac.kr  
논문번호 : 202111-302-B-RN, Received November 5, 2021; Revised February 3, 2022; Accepted February 24, 2022

1×8 filter size. The image-based deep learning model is trained through images that is from the extracted feature data using the pretrained signal-based deep learning network, and predicted each modulation type. The feature size is 24×1, which is extracted through the Fully-Connected layer of the signal-based deep learning network, and the features are converted into Red, Green, and Blue (RGB) images according to the -30 - +30 scale range. The prediction performance of the proposed model shows 2.13%, 4.05% and 9.47% higher accuracy at Signal-to-Noise Ratio (SNR) 10 dB, and 2.12%, 3.4% and 4.26% higher accuracy at SNR 0 dB than the conventional models ECNN, SCGNet and MCNet, respectively.

## I. 서 론

다양한 사물의 연결과 높은 데이터 전송률을 가지는 무선 통신 기술은 산업분야<sup>[1]</sup>, 군사분야<sup>[2]</sup>, 농업분야<sup>[3]</sup> 등 다양한 분야에서 높은 수요를 가지며 국가 경제 발전과 디지털화에 있어서 중요한 요소이다. 통신 하드웨어 발전<sup>[4,5]</sup>에 따라 무선 통신 기술은 1G에서 4G까지 단계적으로 기술발전이 진행되어 왔으며 최근 출현한 5G 통신기술은 높은 대역폭, 높은 전송 속도, 저전력, 등의 다양한 장점을 가진다<sup>[6]</sup>. 사물인터넷은 스마트 시스템을 구현하기 위해 필수적인 요소로 5G 기술 기반 인프라를 통해 구현이 가능하며 5G 기술에 따라 신뢰성 있는 서비스 제공이 가능하다. 하지만, 스펙트럼 자원의 경우 가용 가능한 자원의 한계를 가짐으로 스펙트럼 사용 효율을 높이기 위해 인지 무선 기술이 도입되었다. 인지 무선 기술은 비면허 대역에서 비어 있는 채널에 접근하여 노드간의 통신을 가능하게 하여 스펙트럼 효율을 높이는 기술로 주목받고 있다.

인지 무선 기술은 2차 사용자 간의 통신을 위해 접속 방식과 네트워크 자원에 대한 재구성이 수시로 이루어지므로 다양한 사용자 간의 통신 변조 방식을 인지하기 위한 자동 변조 분류 방식이 제안되었다<sup>[7]</sup>. 자동 변조 분류 방식은 송신 시스템의 사전 정보 없이 동작하므로 사전 정보를 교환하기 위한 프로토콜을 생략과 신호 오버헤드를 줄임을 통해 전송 효율을 높이게 된다. 자동 변조 분류 기법을 구현하기 위해 두 가지 방식으로 구분되며, 먼저는 가능도 기반 방식과

다음은 특징 기반 방식이다. 가능도 기반 방식은 베이저안 추론을 통해 변조 유형의 정확한 분류를 위한 최적의 성능을 나타낸다. 하지만, 신호 샘플 처리 과정에서 일반적으로 높은 계산 복잡도 현상이 발생하므로 시스템 구현에 대한 어려움이 있으며, 예측 초기 단계에 사전 데이터 확보와 완전한 채널 상태 정보를 가져야 하는 제약 조건도 가진다. 특징 기반 방식의 경우 그림 1과 같이 나타낼 수 있으며 수신받은 신호로부터 특징을 추출하여 분류하는 방식으로 가능도 기반 방식보다 성능 부분에서 우수하지는 못하지만 낮은 계산 복잡도로 인해 쉽게 구현할 수 있는 장점을 가진다. 여기서 특징을 추출하기 위해 사용되는 방법은 순간 특징, 순환정지 특징, 고차 쿠플던트 등의 방법이 있으며 추출된 특징은 지도학습 유형의 머신러닝 분류기를 통해 학습과 예측되어 진다. 일반적으로 사용되는 머신러닝 분류기는 Support Vector Machine (SVM)과 Decision Tree (DT), k-Nearest Neighbor (k-NN) 등이 있다. 머신러닝 분류기의 종류에 따라 예측 성능의 차이가 있지만 주어진 특징에 의존적이므로 예측하므로 분류 성능에 한계를 가진다.

컴퓨팅 성능과 빅데이터 처리하기 위한 하드웨어 성능향상으로 음성<sup>[8]</sup>, 자연어 처리<sup>[9]</sup>, 객체 감지<sup>[10]</sup> 등 다양한 분야에 딥러닝 기술이 적용되고 있으며 그중 Convolutional Neural Network (CNN)에 대한 연구가 활발히 이루어지고 있다. 기존 특징 기반 방식과 비교할 때 딥러닝 기술의 우수성은 데이터의 핵심 특징을 자체적으로 추출하여 분류가 가능하고 이에 대한 성능도 매우 우수하다. 최근에는 자동 변조 분류<sup>[11-13]</sup>과 같은 무선 통신 분야에도 CNN 방식을 적용하여 딥러닝 기술의 우수성을 나타내고 있다. 딥러닝 기반 자동 변조 분류 방법은 송신부의 복소 신호를 수집하여 데이터 전처리를 통해 복소 신호를 실수부와 허수부로 구분하여 딥러닝 네트워크 입력으로 전달한 다음 각각 유형별로 학습하여 예측하게 된다. S. H Kim, et al.<sup>[12]</sup>에서는 24개 변조 유형을 예측하는 경량 CNN 모델을 설계하였다. 비록 네트워크의 경량화에

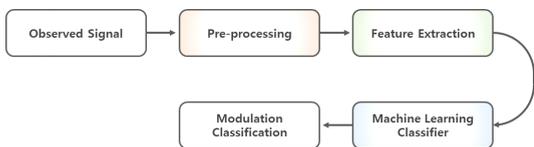


그림 1. 특징 기반 Automatic Modulation Classification (AMC) 아키텍처  
Fig. 1. Feature-based AMC architecture

도 기존 네트워크보다 우수한 성능을 가지는 것을 나타내었다. S. H Kim, et al.<sup>[14]</sup>은 기존의 CNN 모델에서 사용하는 입력 프레임 형태를 확장하여 CNN의 입력으로 사용하여 분류 정확도를 나타내었으며, 계산 복잡도 및 구현을 위한 비용이 매우 낮지만 향상된 예측성능을 나타내었다. G. B Tunze, et al.<sup>[15]</sup>는 CNN에 Depthwise Separable Convolution (DSC) 방식과 기존 2D Convolution 방식을 조합하여 학습 파라미터 수를 줄이고 핵심 특징을 추출할 수 있도록 네트워크를 설계하였다. 제안된 모델은 프레임 크기와 DSC의 Group Convolution 개수에 따른 성능분석과 기존의 모델과의 비교를 통해 우수성을 나타내었다.

본 논문에서 제안된 모델을 통한 기여도는 아래와 같다.

- 신호 기반 CNN 모델을 설계 후 필터 크기에 따른 분류 정확도 성능 분석
- 신호 기반 CNN보다 변조 종류 분류 정확도 향상을 위한 이미지 기반 CNN 모델 제안

최신 데이터셋 RADIOML 2018.01A<sup>[13]</sup> 사용을 통한 모델 성능 검증

본 논문의 구성은 다음과 같다. II장에서는 시스템 모델을 나타내었고, III장에서는 신호 기반 및 이미지 기반 CNN 모델에 대해 설명하였다. IV장에서는 제안된 모델에 대한 성능분석에 대해 나타내었으며, 마지막으로 V장에서 결론 및 향후 연구에 대해 언급하였다.

## II. 시스템 모델

### 2.1 시스템 모델

송신단에서 전송된 신호는 베이스밴드에서 생성된 디지털 신호를 변조하여 Radio Frequency (RF)단을 통해 캐리어 신호로 변환되어 수신단으로 전송된다. 여기서, 송신단에서 Multi-Input Multi-Output (MIMO) 방식으로 신호를 전송하며, 전송된 신호는 24가지 변조 유형 중 하나로 가정하였다. 또한 수신단에서 클럭오프셋과 Rayleigh 페이딩을 통해 손상된 신호를 수집하며, 아래의 식과 같이 나타낼 수 있다.

$$Y = HX + N. \quad (1)$$

여기서  $Y$ 는  $[y_1, y_2 \dots y_{N_r}]$  수신신호 벡터이며,  $H$ 는  $[h_{11}, h_{12}, \dots, h_{21} \dots h_{N_r, N_t}]$  채널 행렬,  $X$ 는  $[x_1, x_2 \dots x_{N_t}]$  패킷 벡터 그리고  $N$ 은 Additive White Gaussian

Noise (AWGN)이다.  $N_t$ 와  $N_r$ 는 송수신단의 안테나 수이다.

수신된 신호는 복소 신호이며, 전처리단을 통해 신호를 처리하여 신호 기반 CNN의 입력으로 전달된다. 전처리단에서 복소 신호를  $N$  길이의 프레임 단위로 재구성하여 정규화하고 실수부, 허수부 벡터로 분리하는 과정을 거친다. 프레임 정규화는 Root Mean Square (RMS) 방식으로 수행하며 아래의 식으로 나타낸다.

$$\bar{s}_i = \frac{s_i}{\sqrt{\frac{1}{N} \sum_{i=1}^N |s_i|^2}}. \quad (2)$$

여기서  $s_i$ 는 프레임에서 하나의 요소를 나타내며 각 프레임의 길이  $N$ 은 1024이다. 정규화된 프레임은 실수부 벡터와 허수부 벡터로 분리되어  $2 \times 1024$  행렬 구성하며 학습 및 예측을 위해 딥러닝 네트워크로 전달된다.

### 2.2 데이터셋

제안된 모델의 성능분석을 위해 사용된 데이터셋은 DEEPSIG의 RadioML 2018.01A<sup>[13]</sup>를 사용하였다. 총 24가지 변조 유형을 가지며 SNR 범위 -20dB에서 +30dB까지 2dB 간격을 따라 데이터가 수집되었다. 각 유형 당 각 SNR 구간에서 4096개의 프레임 수를 가지며, 따라서 SNR 전 구간에서 수집된 프레임 수는 2,555,904개이다. 학습을 위해 적용되는 프레임 수는 각 변조 유형이 가지는 프레임의 70%를 할당하고, 검증을 위해 10% 그리고 시험을 위해 20%를 할당하였다.

## III. 제안된 딥러닝 모델

### 3.1 CNN 모델

딥러닝 네트워크 CNN은 머신러닝의 지도학습 범위로 분류되며 인공지능경망에서 확장되었다. 초기 CNN은 이미지 분류를 위해 연구되었으나 현재 다양한 분야 응용되고 있다. CNN은 전처리단에서 처리된 입력값을 컨볼루션 레이어를 통해 특징맵을 생성하며 컨볼루션 연산은 아래의 식과 같이 나타낼 수 있다.

$$z(i) = \sum_{i=1} x(i)w(i) + b \quad (3)$$

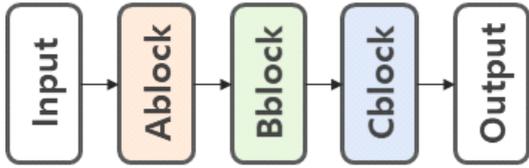


그림 2. 신호 기반 CNN 아키텍처  
Fig. 2. Signal-based CNN (SBCNN) architecture

여기서  $x(i)$ 는 입력값,  $w(i)$ 는 컨볼루션 계수이고 그리고  $b$ 는 바이어스 값이다. 컨볼루션 레이어를 통해 생성된 특징맵은 활성화 레이어를 통해 비선형적으로 적층하게 되며, 여기서 일반화 성능을 높이기 위해 컨볼루션 레이어와 활성화 레이어 사이 배치 정규화 레이어를 사용한다. 활성화 레이어 중 일반적으로 사용하는 함수는 Rectified Linear Units (ReLU) 함수로 아래 식과 같이 나타낼 수 있다.

$$f(z(i)) = \operatorname{argmax}(z(i), 0) \quad (4)$$

사용되는 맥스 풀링 레이어와 평균 풀링 레이어는 적용되는 필터 크기  $k$ 에 따라  $z(1, 2, \dots, k)$ 의 범위에서 축소된다. 마지막으로 완전 연결 레이어를 통해 특징맵을 1차원 배열로 나열하고 Softmax 레이어에 각 변조 유형에 대한 예측확률을 계산하고 최종 예측하게 된다. 본 논문에서는 매개변수 최적화를 위해 Stochastic Gradient Descent with Momentum (SGDM)를 사용하여 가중치를 갱신하였다.

### 3.2 신호 기반 CNN

신호 기반 CNN은 복소수 신호로 구성된 프레임을 학습하여 신호의 변조 종류를 분류하는 것을 목적으로 한다. CNN이 변조 분류를 위해 적용된 이유는 기존 머신러닝 모델이 가지는 handcraft 특징을 통해 얻을 수 있는 분류 정확도의 한계를 극복하기 위해서 제안되었다. 제안된 구조는 A, B, C 블록을 사용하여 특징맵을 생성하도록 하였고 Output을 통해 분류 예측하도록 하였다. Ablock의 경우 그림 4(a)처럼 Visual Geometry Group (VGG)와 같은 형태로 컨볼루션 레이어를 순차적으로 적용하였고 비대칭 필터를 사용하여 입력의 가로, 세로 방향으로 특징맵을 생성하도록 하였다. 또 MaxPooling (MPool) 레이어를 통해 의미 없는 특징 샘플을 제거하여 입력의 크기를 줄이도록 하였다. Bblock은 그림 4(b)와 같이 크게 2단으로 거쳐 특징맵을 생성하도록 설계 되었고 첫 단과 다음 단에 걸쳐 ConvB (1×1), (1×8), (3×1) 간에 스킵커넥

션으로 연결하여 정확도를 높이도록 하였다. 여기서 ConvB은 Convolution 블록을 의미하며 Convolution 레이어, 배치 정규화 레이어 그리고 활성화 레이어 조합으로 되어있으며 (1×1), (1×8), (3×1)는 필터 크기를 의미한다. 그림 4(c)의 Cblock은 AveragePooling (APool) 레이어를 통해 2Dimension (D)을 1D으로 압축하도록 하였고, 따라서 계산 복잡도를 낮추도록 하였다. 1D 특징맵은 그림 4(b)와 같이 2단에 걸쳐 특징맵을 생성하며 Global Average Pooling (GAPool) 통해 특징맵 크기를 단일 크기로

표 1. 신호 기반 CNN 구조 설명  
Table 1. The description of SBCNN.

Type	Filter Size	Output Size	Parameters	
Input	-	2×1024	-	
Ablock	ConvB	1×8	2×1024×32	352
	ConvB	3×1	2×1024×32	318
	MPool	1×2	2×512×32	-
	ConvB	1×8	2×512×32	8,288
	ConvB	3×1	2×512×32	3,168
	MPool	1×2	2×512×32	-
BBlock	ConvB	1×1	2×256×32	1,120
	ConvB	1×8	2×256×16	4,144
	ConvB	3×1	2×256×16	816
	ConvB	1×1	2×256×32	608
	ConvB	1×1	2×256×32	1,120
	ConvB	1×8	2×256×16	4,144
	ConvB	3×1	2×256×16	816
	ConvB	1×1	2×256×32	608
	APool	2×1	1×256×32	-
CBlock	ConvB	1×1	1×256×64	2,240
	ConvB	1×8	1×256×32	16,480
	ConvB	1×1	1×256×64	4,240
	ConvB	1×1	1×256×64	4,288
	ConvB	1×8	1×256×32	16,480
	ConvB	1×1	1×256×64	2,240
	GAPool	-	1×1×64	-
	DO	-	-	-
	FC	-	1×1×64	1,560
Output	Softmax	-	1×1×24	-
	Output	-	1×1×24	-
	Total	-	-	73,030

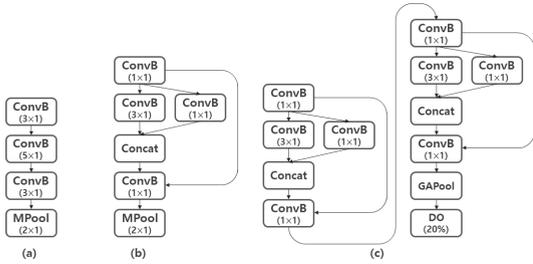


그림 3. 이미지 기반 CNN 블록 구조 (a)ABlock (b)Bblock (c)Cblock  
 Fig. 3. Image-based CNN (IBCNN) block structure (a)ABlock (b)Bblock (c)Cblock

완전 축약한다. 마지막 단의 ConvB로부터 전달된 채널 수 64개는 DropOut (DO) 레이어를 통해 랜덤하게 20%의 확률로 뉴런을 가중치 갱신에 제외하여 일반화 성능을 높이게 하였다. 그림 4(d)의 Output은 Fully-Connected (FC) 레이어, SoftMax (SM) 레이어 그리고 Classification Output (CO) 레이어를 통해 최종 예측을 하게 된다. 신호 기반 CNN 아키텍처의 구체적 설명은 표 1을 통해 나타내었다.

### 3.3 이미지 기반 CNN

이미지 기반 CNN은 기존 신호 기반 CNN에서 가지는 분류 정확도를 향상시키기 위해 24가지 변조 종류의 이미지를 학습 및 분류하도록 제안되었으며, 학습을 위한 과정은 이미지 기반 CNN은 신호 기반 CNN을 데이터셋을 통해 학습을 시킨 후 동일한 데이터셋을 사전 훈련된 신호 기반 CNN을 통해 특징을 추출한 다음 추출된 특징을 -30 - +30 스케일 범위에 따라 이미지로 변환시켜 이미지를 학습하도록 하였다. 여기서 변환된 이미지는 스케일에 따라 다른 색상을 가지도록 한다. 추출된 특징은 사전 훈련된 네트워크의 FC를 통해 추출하였으며 FC를 통해 추출되기 전 신호 기반 CNN에 사용된 프레임과 같이 동일한 전처리를 거친다. 추출된 특징은 24x1의 크기를 가지며, 이미지로 변환 후 이미지의 크기는 계산 복잡도를 고려하여 24x1x3을 크기로 재조정하였다. 마지막으로 조정된 이미지는 이미지 기반 CNN의 학습을 위해 사용된다. 이미지 기반 CNN 구조는 그림 3과 같이 신호 기반 CNN 구조와 동일하게 구분되며, 각 블록에 대한 구조도 유사하게 설계하였으며 그림 5를 통해 나타내었다. 여기서 Output은 그림 4(d)와 같으므로 생략하였다. Ablock은 3개의 ConvB와 하나의 MPool가 사용되었으며 ConvB가 순차적으로 동작된 다음 MPool으로 특징맵을 줄이도록 하였다. Bblock

표 2. 이미지 기반 CNN 구조 설명  
 Table 2 The description of image-based CNN.

Type	Filter Size	Output Size	Parameters	
Input	-	24 × 1 × 3	-	
ABlock	ConvB 3 × 1	24 × 1 × 32	384	
	ConvB 5 × 1	24 × 1 × 16	2,608	
	ConvB 3 × 1	24 × 1 × 32	1,632	
	MPool 2 × 1	12 × 1 × 32	-	
BBlock	ConvB 1 × 1	12 × 1 × 32	1,120	
	ConvB 3 × 1 (C1)	12 × 1 × 16	1,584	
	ConvB 1 × 1 (C2)	12 × 1 × 16	560	
	ConvB 1 × 1	12 × 1 × 32	1,120	
CBlock	MPool 2 × 1	6 × 1 × 32	-	
	ConvB 1 × 1	6 × 1 × 64	2,240	
	ConvB 3 × 1 (C1)	6 × 1 × 16	3,120	
	ConvB 1 × 1 (C2)	6 × 1 × 16	1,072	
	ConvB 1 × 1	6 × 1 × 64	2,240	
	ConvB 1 × 1	6 × 1 × 128	8,576	
	ConvB 3 × 1 (C1)	6 × 1 × 32	12,384	
	ConvB 1 × 1 (C2)	6 × 1 × 32	4,192	
	ConvB 1 × 1	6 × 1 × 128	8,576	
	GAPOOL	-	1 × 1 × 128	-
DO	-	1 × 1 × 128	-	
Output	FC	-	1 × 1 × 24	3,096
	Softmax	-	1 × 1 × 24	-
	Output	-	1 × 1 × 24	-
Total	-	-	54,504	

은 그림 5(b)와 같이 처음 (1x1) ConvB를 시작으로 (3x1)와 (1x1) ConvB를 통해 생성된 특징맵을 연결하여 (1x1) ConvB로 전달되어 처음 (1x1) ConvB와 스킵커넥션으로 연결된 다음 MPool 연산을 수행한다.

## IV. 모의실험 및 성능분석

### 4.1 신호 기반 CNN

신호 기반 CNN (SBCNN)과 이미지 기반 CNN (IBCNN)의 모의실험을 위해 데이터셋의 70%는 학습

데이터로 10%는 검증을 위해 그리고 20%는 시험용으로 분할하여 성능에 대해 나타내었다. 시험 해석 프로그램은 Matlab 2020b를 사용하였으며 하드웨어 장비는 CPU i5-9400F, RAM 32GByte, GPU NVIDIA RTX 2080 SUPER으로 구성하였다. 제안된 모델과 성능 비교를 위하여 최신 CNN 모델인 ECNN<sup>[14]</sup>, SCGNet<sup>[15]</sup>, LCNN<sup>[12]</sup> 등과 SNR에 따른 비교를 통해 성능을 나타내었다. 모의실험을 위한 세부 환경 설정은 표 3를 통해 요약하였다.

성능 분석은 0 dB - +20 dB SNR 구간에서 제안된 모델과 기존 모델과의 예측 성능을 나타내었다. 이는 낮은 SNR 영역에서는 페이딩 등의 영향으로 각 신호의 구분이 명확하지 않으며, 따라서 CNN을 통해 식별 가능한 특징 추출 또한 쉽지 않아 전체적으로 낮은 예측 정확도를 가지기 때문이다. 그림 6은 SBCNN을 포함한 각 기법에 대한 성능 비교를 나타내었으며, SBCNN이 SNR 전 구간에서 우수한 예측 성능을 가지는 것을 볼 수 있다. 0 dB에서 ECNN, SCGNet, LCNN 그리고 SBCNN은 57.51%, 54.37%, 56.64% 그리고 57.77% 예측 성능을 보였고 10 dB에서는 94.15%, 88.12%, 91.48% 그리고 95.53% 성능을 가진다. 따라서, SBCNN의 예측 정확도가 0 dB에서 최소 0.16%, 10 dB에서 최소 1.38% 높은 것을 알 수 있다. 이는 낮은 SNR보다 높은 SNR 영역에서 24가지 유형에 대한 신호 왜곡이 적고, 각 유형에 대한 핵심 특징이 잘 추출되어 예측 성능이 높은 것을 알 수 있다. 그림 7은 SBCNN에서 (1×8) 필터를 사용하는 컨볼루션 레이어를 (1×3)과 (1×5)로 변경하였을 때 이에 대한 예측 성능 영향에 대해 나타내었다. 성능 결과에 따라 (1×3) 필터를 사용하였을 때 가장 낮은 성능이 나오는 것을 볼 수 있으며, (1×8) 필터와 성능 차이가 큰 폭으로 발생하는 것을 볼 수 있다. 필터 크기가 커질 경우 학습 파라미터 양도 크게 증가되며 이에 따라 계산 복잡도 역시 비례하여 증가하게 됨

표 3. 신호 기반 CNN 모의실험 설정  
Table 3. The configuration for signal-based CNN simulation.

Type	Value
MaxEpochs	40
MiniBatchSize	64
InitialLearnRate	0.1
LearnRateDropPeriod	35
LearnRateDropFactor	0.1
Optimizer	SGDM

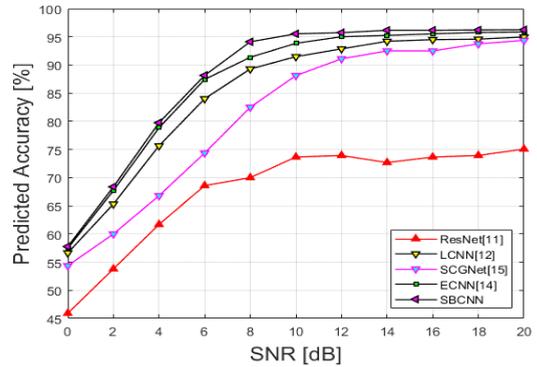


그림 4. SBCNN 모델의 성능 비교  
Fig. 4. Performance comparison of SBCNN model

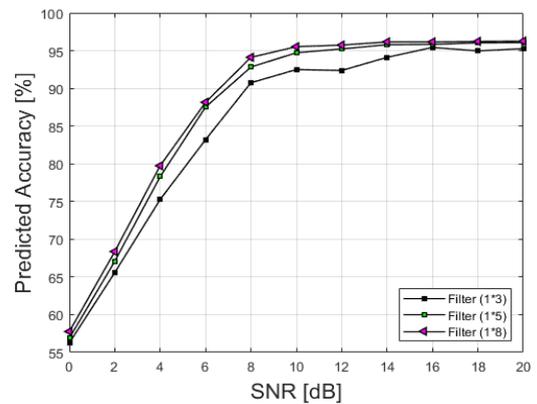


그림 5. SBCNN의 필터크기에 따른 성능 비교  
Fig. 5. Performance comparison of SBCNN filter size types

로, 채널 수를 조정하여 학습 파라미터 양을 낮추도록 하였다. 또한 (1×8) 필터와 (1×5) 필터의 정확도 성능 차이가 크게 나지 않음으로 (최대 1.45%, 4 dB) 적용하는 분야에 따라 필터 크기를 조정하여 사용이 가능하다.

#### 4.2 이미지 기반 CNN

이미지 기반 CNN (IBCNN)의 입력으로 사용하기 위해 SBCNN으로부터 특징을 추출하여 이미지로 변환하였으며 그림 8을 통해 SNR 10 dB에서 24가지 유형에 대한 변환된 이미지를 나타내었다<sup>[6]</sup>.

변환된 이미지는 IBCNN에 사용하기 위해 24×1 크기로 변환하였는데 이는 추출된 특징 크기가 24×1이며 24 픽셀로 이미지 특징 정보를 모두 포함 가능하기 때문이다. 또한 이미지 크기를 재조정하므로 계산 복잡도도 역시 낮출 수 있다. 모의실험을 위한 환경 설정은 MaxEpoch 20, LearnRateDropPeriod 5로 설정

표 4. 각 변조 유형에 대한 성능 비교 분석  
Table 4. The performance comparison of each modulation.

SNR	Name	128APSK	128QAM	16APSK	16PSK	16QAM	256QAM	32APSK	32PSK	32QAM	4ASK	64APSK	64QAM
0dB	ECNN	4.3	6.8	77	33.6	100	63.6	49	100	81.6	5.9	13.2	69.1
	SBCNN	15.8	7.8	74.1	25.8	99.7	65.2	68.1	100	83.1	9.28	24.5	49.8
	IBCNN	4.5	8	79.3	35.4	99.8	64.5	52.8	100	81.5	23.2	21.8	56.2
2dB	ECNN	18.2	14.8	75.6	58.9	100	69	84.9	100	92.2	39.7	24.1	64.6
	SBCNN	10.3	1.5	60	67.7	100	55.4	85.5	100	97.6	35.6	33.3	49.4
	IBCNN	17.7	18.4	85.1	72.8	100	67.2	88.6	100	81.9	52.3	33.5	67.1
4dB	ECNN	27.4	31.9	96.3	96.8	100	65.8	99.9	100	94.7	62.3	58.9	62.1
	SBCNN	45.3	28.4	95.8	99.1	100	66	100	100	99	72.4	71.4	61.6
	IBCNN	56.2	40.2	98.1	99.1	100	64.3	99.8	100	98.4	70.2	74.4	61.5
6dB	ECNN	57.4	58.7	89.8	99	100	68.4	100	100	99.3	80.8	87.2	62.3
	SBCNN	76.1	36.2	99.8	100	100	65.5	100	100	99.8	89.3	91.9	54.5
	IBCNN	81.8	64.4	100	100	100	63	100	100	99.8	94.1	95.2	64.3
8dB	ECNN	78	73.9	100	99.6	100	69.1	100	100	99.8	93.7	96.7	64.3
	SBCNN	89.3	85.1	100	99.88	100	66.3	100	100	99.8	98.4	99.5	59.5
	IBCNN	93.6	88.8	100	100	100	68.1	100	100	100	99.7	99.2	63.9
10dB	ECNN	86.9	88.6	100	99.6	100	65.6	100	100	99.9	97.4	99.1	63.1
	SBCNN	94.5	93.7	100	100	100	62.5	100	100	100	99.6	100	60.6
	IBCNN	95.9	95.4	100	100	100	66.3	100	100	100	99.8	99.7	65.2
12dB	ECNN	91.1	92.4	100	99.8	100	68.1	100	100	100	99	99.5	63.1
	SBCNN	99	97.4	100	100	100	69.1	100	100	100	99.8	100	67
	IBCNN	97.3	98	100	100	100	67	100	100	100	100	100	68.6
14dB	ECNN	92.4	93.2	100	99.8	100	64.5	100	100	100	98.8	99.8	61.3
	SBCNN	96.2	97.9	100	100	100	67.1	100	100	100	100	100	65.9
	IBCNN	98	97.4	100	100	100	67.5	100	100	100	100	100	65.2
SNR	Name	8ASK	8PSK	AM-DSB-SC	AM-DSB-WC	AM-SSB-SC	AM-SSB-WC	BPSK	FM	GMSK	OOK	OQPSK	QPSK
0dB	ECNN	23.7	56.4	15.5	100	15.3	66.4	74	100	98.7	100	31.6	73.1
	SBCNN	2.08	66.1	22.3	100	7.08	83.8	73.6	100	98.9	100	32.3	76.5
	IBCNN	36.6	69.7	26.9	100	16.3	79.4	81.5	100	99.3	100	12.9	80.2
2dB	ECNN	49.7	79	33.6	100	19.3	87.9	92.3	100	100	100	36.5	84.1
	SBCNN	61.1	83.5	52.2	100	38.3	95.9	95.2	100	100	100	26.2	91.3
	IBCNN	50.1	91.8	48.2	100	28.5	89.01	95.9	100	100	100	41.6	86.8
4dB	ECNN	63.7	95.6	41.4	100	41.1	92.6	99	100	100	100	50.4	90.4
	SBCNN	3.3	97.1	44.8	100	52.7	90.9	99.2	100	100	100	96.2	90.2
	IBCNN	63.3	99.2	49.6	100	64.9	92.5	100	100	100	100	45.6	93.6
6dB	ECNN	79.4	99	44.2	100	82.7	94.5	100	100	100	100	95.5	89.7
	SBCNN	67.5	100	68.8	100	94.5	98.2	99.8	100	100	100	80.4	92.4
	IBCNN	79.2	100	58	100	95.1	93.77	100	100	100	100	74.3	94.5
8dB	ECNN	97.2	99.6	56	100	93.4	94.9	100	100	100	100	99.8	93.2
	SBCNN	98.2	100	70.4	100	99.3	97.9	100	100	100	100	100	94.8
	IBCNN	99.1	100	83.5	100	99.5	95.1	100	100	100	100	99.6	92.5
10dB	ECNN	98	100	71.6	100	98.8	97.2	99.9	100	100	100	100	93.9
	SBCNN	99.7	100	87.5	100	99.8	98.2	100	100	100	100	100	96.2
	IBCNN	100	100	94.1	100	100	94.5	100	100	100	100	100	94.9
12 dB	ECNN	99.4	100	78	100	99.1	96.9	100	100	100	100	100	95.1
	SBCNN	99.8	100	81.56	100	100	93	100	100	100	100	100	90.9
	IBCNN	100	99.8	96.4	100	100	93.2	100	100	100	100	100	93.8
14 dB	ECNN	99.5	99.9	86.3	100	99.4	98.2	100	100	100	100	100	93.9
	SBCNN	100	100	92.31	100	100	93.7	100	100	100	100	100	94.6
	IBCNN	100	100	96.7	100	100	94.9	100	100	100	100	100	95.2

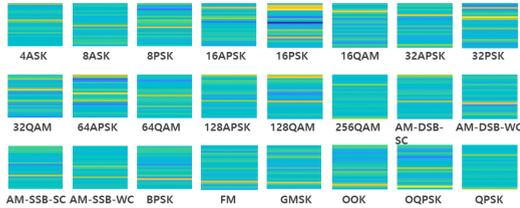


그림 6. 변환된 24개 변조 종류 이미지  
Fig. 6. Converted images of 24 modulation types

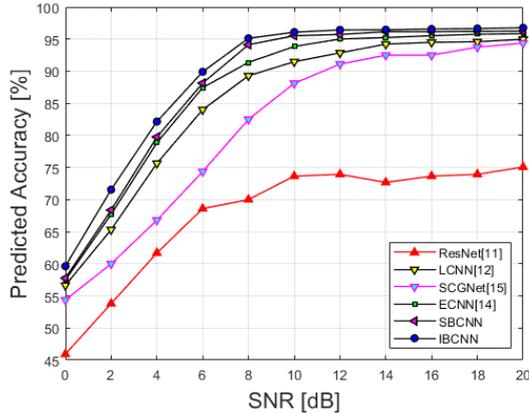


그림 7. IBCNN 모델의 성능 비교  
Fig. 7. Performance comparison of IBCNN model

하였으며 나머지 설정은 표 3과 동일하다. 그림 9는 IBCNN을 포함한 성능 비교를 나타내었고 SBCNN보다 크게 향상된 것을 볼 수 있다. 특히, 0 dB - 10 dB 사이 IBCNN의 성능이 큰 폭으로 향상되는 것을 볼 수 있으며 SBCNN보다 최대 3.18% (2 dB) 되었다.

24 변조 각각에 대한 성능 차이를 표 4를 통해 나타내었으며 예측 정확도가 우수한 상위 3가지 모델만 고려하였다. SNR 범위 16 dB에서 20 dB는 성능 차이가 크게 없으므로 생략하였다. 또 성능 차이가 1% 이상 가지는 부분에 볼드체로 표시를 하였다. 표 4에 나타난 것과 같이 0 dB에서 10 dB 사이에서 정확도 차이가 두드러지게 나타났으며, 특히 4 dB에서 IBCNN이 1% 이상 우수한 예측 정확도를 가지는 변조 방식이 8개가 있으며 SBCNN는 2개 ECNN은 0개가 있다. 또 128APSK, 128QAM, 16APSK, 4ASK, 8PSK 그리고 AM-DSB-SC는 SBCNN이 다른 네트워크보다 우수하게 예측하는 것을 볼 수 있다. 3가지 네트워크가 공통으로 64QAM와 256QAM 방식에 대해 SNR이 증가함에도 예측 성능이 향상되지 않은 것을 볼 수 있다. 이는 64QAM의 경우 AM-SSB\_WC 방식과 추출된 특징이 유사하여 혼돈하기 때문이며,

256QAM의 경우 QPSK 방식과 유사하기 때문이다. AM-DSB-SC는 128APSK와 128QAM과 혼돈되어 낮은 SNR 영역에서는 예측 정확도가 매우 낮지만 SNR이 증가함에 따라, 특히 8 dB 이상에는 IBCNN의 성능이 크게 향상되어 80% 이상의 예측 성능을 보인다. 반면에 ECNN의 경우에는 20 dB에서 89%의 성능으로 다른 네트워크에 비해 성능이 낮은 것을 볼 수 있다.

### V. 결론 및 향후 연구

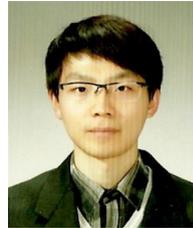
본 논문에서는 인지 통신에 사용되는 자동 변조 분류를 위해 사전훈련된 네트워크를 사용하여 이미지 기반 딥러닝 모델을 설계하였다. 사전훈련된 네트워크를 통해 추출된 특징은 신호 기반 딥러닝 네트워크의 FC 레이어를 통해 24×1 특징 크기로 추출하였으며 각 특징이 가지는 특징값은 -30 - +30 스케일 범위에 따라 RGB 이미지로 변환하였다. 제안된 모델의 예측 정확도 성능은 SNR 10 dB에서 기존 ECNN, SCGNet 그리고 LCNN 보다 1.38%, 7.41% 그리고 4.05% 높은 예측 정확도를 보였으며 SNR 0 dB에서는 0.26%, 3.4% 그리고 1.13% 각각 높은 성능을 보였다. 향후 연구로는 왜곡된 신호를 전처리를 통해 신호 손상을 보정하고 각 변조에 대한 핵심 특징 추출에 대한 방식을 연구할 예정이다.

### References

- [1] S.-H. Kim, J.-W. Kim, and D.-S. Kim, "Energy consumption analysis of beamforming and cooperative schemes for aircraft wireless sensor networks," *Applied Sci.*, vol. 10, no. 12, pp. 4374-4391, Jun. 2020.
- [2] S. Rizal, D. A. Nugroho, S.-H. Kim, and D.-S. Kim, "Rate adaptation algorithm for multicast communication in tactical networks," in *Proc. IEEE MILCOM*, pp. 109-114, Tampa, USA, Oct. 2015.
- [3] M. R. Ramli, P. T. Daely, D.-S. Kim, and J.-M. Lee, "IoT-based adaptive network mechanism for reliable smart farm system," *Comput. and Electron. in Agric.*, vol. 170, pp. 1-8, 2020.
- [4] J.-W. Kim, D.-S. Kim, S.-H. Kim, and S.-M. Shin, "The firmware design and implementation

- scheme for C form-factor pluggable optical transceiver,” *Applied Sci.*, vol. 10, no. 6, pp. 1-19, Mar. 2020.
- [5] J.-W. Kim, D.-S. Kim, S.-H. Kim, and S.-M. Shin, “Design and implementation scheme of QSFP28 optical transceiver for long-reach transmission using PAM4 modulation,” *Applied Sci.*, vol. 11 no. 6, pp. 1-19, Mar. 2021.
- [6] G. C. Amaizu, C. I. Nwakanma, S. Bhardwaj, J.-M. Lee, and D.-S. Kim, “Composite and efficient DDoS attack detection framework for B5G networks,” *Comput. Netw.*, vol. 188, pp. 1-10, Jan. 2021.
- [7] T. Huynh-The, C. Hua, J.-W. Kim, S.-H. Kim, and D.-S. Kim, “Exploiting a low-cost CNN with skip connection for robust automatic modulation classification,” in *Proc. IEEE WCNC*, pp. 1-6, Seoul, Republic of Korea, May 2020.
- [8] J. Salamon and J. P. Bello, “Deep convolutional neural networks and data augmentation for environmental sound classification,” *IEEE Sign. Process. Lett.*, vol. 24, no. 3, pp. 279-283, Mar. 2017.
- [9] T. He, W. Huang, Y. Qiao, and J. Yao, “Text-attentional convolutional neural network for scene text detection,” *IEEE Trans. Image Process.*, vol. 25, no. 6, pp. 2529-2541, Jun. 2016.
- [10] T. Huynh-The, C. Hua, N. A. Tu, J.-W. Kim, S.-H. Kim, and D.-S. Kim, “3D action recognition exploiting hierarchical deep feature fusion model,” in *Proc. IEEE IMCOM*, pp. 1-3, Taichung, Taiwan, Jan. 2020.
- [11] T. J. O’Shea, T. Roy, and T. C. Clancy, “Over-the-air deep learning based radio signal classification,” *IEEE J. Sel. Topics in Sign. Process.*, vol. 12, no. 1, pp. 168-179, Feb. 2018.
- [12] S.-H. Kim, J.-W. Kim, V.-S. Doan, and D.-S. Kim, “Lightweight deep learning model for automatic modulation classification in cognitive radio networks,” *IEEE Access*, vol. 8, pp. 197532-197541, Oct. 2020.
- [13] deepsig.ai, “*RF Datasets For Machine Learning*,” 2018. [Online]. Available: <https://www.deepsig.ai/datasets>.
- [14] S.-H. Kim, J.-W. Kim, W.-P. Nwadiugwu, and D.-S. Kim, “Deep learning-based robust automatic modulation classification for cognitive radio networks,” *IEEE Access*, vol. 9, pp. 92386-92393, Jun. 2021.
- [15] G. B. Tunze, T. Huynh-The, J.-M. Lee, and D.-S. Kim, “Sparsely connected CNN for efficient automatic modulation recognition,” *IEEE Trans. Veh. Technol.*, vol. 69, no. 12, pp. 15557-15568, Dec. 2020,
- [16] S.-H. Kim, C.-B. Moon, J.-W. Kim, and D.-S. Kim, “A hybrid deep learning model for automatic modulation classification,” *IEEE Wireless Commun. Lett.*, pp. 1-5, Nov. 2020. [In Press]

김 승 환 (Seung-Hwan Kim)



2010년 8월 : 금오공과대학교 전  
자공학부 졸업

2012년 8월 : 금오공과대학교 전  
자공학과 석사 졸업

2018년 8월 : 금오공과대학교 전  
자공학과 박사 졸업

2018년 8월~2021년 11월 : ICT  
융합특성화연구센터 연구교수

2021년 12월~현재 SK실트론 Pro

<관심분야> 심층 인공지능경망, 인지 무선 네트워크, 무  
선 센서 네트워크

[ORCID:0000-0002-4118-8703]

**문 창 배 (Chang Bae Moon)**



2007년 : 금오공과대학교 소프트웨어공학과 공학사  
2010년 : 금오공과대학교 소프트웨어공학과 공학석사  
2013년 : 금오공과대학교 소프트웨어공학과 공학박사  
2013년~2014년 : 영풍전 (주) 선임연구원

2014년~현재 : 금오공과대학교 ICT융합특성화센터 연구교수

<관심분야> 인공지능, 영상처리, 지식검색, 감성공학

**김 등 성 (Dong-Seong Kim)**



1992년 2월 : 한양대학교 전자공학과 졸업  
2003년 3월 : 서울대학교 전기 및 컴퓨터공학부 박사졸업  
2004년 : Cornell 대학교 ECE 박사 후 연구원  
2004년 3월~현재 : 금오공대 전자공학부 정교수

2014년~현재 : ICT융합특성화연구센터 센터장 (과기정통부 Grand ICT 및 연구재단 중점연구소)

2019년~2022년 2월 : 금오공과대학교 산학협력단 단장

2014년~현재 : IEEE/ACM Senior 회원

2015년~2017년 : 금오공대 융합기술원 원장

2016년 9월~현재 : 국방부 CIO 자문위원

<관심분야> 실시간 통신망 및 IoT 시스템, 네트워크 기반 분산제어시스템 시스템, 실시간 S/W

[ORCID:0000-0002-2977-5964]

**권 기 협 (Ki-Hyeob Kwon)**



2000년 2월 : 금오공과대학교 전자공학부 졸업  
2003년 2월 : 금오공과대학교 전자공학부 석사 졸업  
2019년 8월 : 금오공과대학교 전자공학과 박사 졸업

2014년 7월~현재 : ICT융합특성화연구센터 팀장

<관심분야> 산업용 IoT, 5G, 머신러닝