

# 인지 무선 통신망의 자동 변조 분류를 위한 딥러닝 모델 설계

김승환\*, 김치윤\*, 유상호\*, 김동성°

## Design of Deep Learning Model for Automatic Modulation Classification in Cognitive Radio Network

Seung-Hwan Kim\*, Chi-Yoon Kim\*, Sang-Ho Yoo\*, Dong-Seong Kim°

### 요약

본 논문에서는 인지 무선 기술에서 자동 변조 분류를 수행하기 위하여 경량 합성곱 신경망 모델을 제안하였다. 제안된 모델은 vanishing gradient 문제를 최소화하기 위해 ResNet의 skip connection 구조를 적용하였으며, 또 모델을 병목 구조 형태로 설계함으로 일반적인 합성곱 신경망 모델보다 연산량을 낮추도록 하였다. 제안된 모델을 통한 특징 추출을 하기 위해 입력 데이터 동기화와 정규화 그리고 고차원으로 데이터 재구성을 하였으며, 성능 평가를 위하여 24개의 변조 방식을 가지는 데이터셋을 사용하여 기존의 심층 학습 네트워크인 ResNet과 VGG 그리고 AMC-CNN의 정확도 성능 및 예측 시간을 비교하였다. Matlab 2019b 모의실험 프로그램을 통해 제안된 모델의 성능이 기존의 모델보다 전체 SNR (Signal-to-Noise Ratio) 영역에서 예측 정확도 성능이 우수한 것을 확인하였으며, 특히 SNR 10 dB에서 최대 31.59% 이상 높은 정확도를 보였다. 입력 신호를 예측하는 시간 또한, 최대 47.5% 이상 기존 모델보다 빠르게 예측하는 것을 확인하였다.

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

### ABSTRACT

In this paper, light weight deep learning-based light weight Convolutional Neural Network (CNN) model is proposed for automatic modulation classification in cognitive radio. To minimize the vanishing gradient problem the skip connection structure of ResNet is applied to the proposed model, and to reduce computation complexity the proposed model is designed as bottleneck architectures. To extract the features through the proposed model synchronization, normalization, and aggregation dealt with for the input signals, and for performance evaluation the proposed model is compared with the conventional networks, ResNet and VGG, about the accuracy and inference by using the dataset that has 24 modulation classes. According to the simulation result by Matlab analysis tool, the proposed model has better performance on the predicted accuracy than others, especially over than 10% at SNR 10 dB. The performance of inference time also has smaller time than others.

\* 본 연구는 한국연구재단의 “대학중점연구소 및 Grand ICT연구센터 지원사업(2018R1A6A1A03024003, IITP-2020-2020-0-01612)”으로 수행된 연구결과임.

• First Author : Kumoh National Institute of Technology ICT Convergence Research Center, ksh001@kumoh.ac.kr, 정회원

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

\* Kumoh National Institute of Technology IT Convergence engineering, 20196075@kumoh.ac.kr, 학생회원; 20186116@kumoh.ac.kr, 학생회원

논문번호 : 202003-048-C-RN, Received March 5, 2020; Revised June 4, 2020; Accepted June 16, 2020

## I. 서 론

최근 사물인터넷 보급과 모바일 서비스의 급격한 증가로 등으로 인해 다양한 응용 분야별로 제한적인 주파수 대역을 통한 안정적인 서비스를 제공에 어려움을 가진다<sup>[1]</sup>. 따라서, 주파수 대역의 사용효율을 높이기 위해 여러 해결방법이 있으며 그중 한 가지로 인지 무선 기술이 제안되었다<sup>[2]</sup>. 인지 무선 기술은 주사용자에게 간섭을 주지 않는 범위 내에서 비어 있는 채널을 감지하여 해당 채널로 이동을 하는 기술이다. 이때 채널에 따른 변조기법이 변화될 수 있어 인지 무선 기술은 채널에 따라 변조기법을 자동적으로 선택하는 자동 변조 분류 기능을 포함한다<sup>[3]</sup>. 자동 변조 분류는 신호에 대한 사전지식 없이 자동적으로 신호의 변조 종류를 식별해내는 기능이다. 일반적으로 자동 변조 분류기능은 2가지 기법으로 구분할 수 있으며 첫 번째는 최대 우도추정 기반의 의사결정 이론 기법이 있으며 두 번째는 특징 기반의 패턴인식 기법이 있다. 최대 우도추정 방식은 베이저안 추론을 통해 최적의 값을 얻을 수 있는 장점을 가지지만<sup>[4]</sup> closed-form 방정식으로 도출하기 어려우며 높은 계산복잡도를 가짐으로 현실적으로 구현이 어려운 등의 단점들이 있다. 특징 기반의 패턴인식 방식은 3단계로 구분할 수 있으며, 첫 번째는 입력 데이터 전처리, 그리고 특징 추출, 마지막으로 분류 결정으로 진행된다. 자동 변조 분류 기법에서 특징 추출 기반 방식은 데이터로부터 특징 추출을 위한 충분한 데이터 크기가 요구되며 이는 네트워크 지연을 일으킬 수 있다. 이러한 단점을 해결하기 위해 관련 연구가 진행되었지만<sup>[5]</sup>, 자동 변조 분류를 위한 기존의 특징 기반 방식은 고차 통계 처리 시 특징 계산을 위해 많은 시간을 소모하는 한계를 가진다. 인공지능의 상당한 발전<sup>[6]</sup>으로 인한 심층 기계 학습이 제안<sup>[7-10]</sup>되었으며 자동 변조 분류 분야에서 우수한 데이터처리 성능을 가진다. Z. Zhang, et al.<sup>[11]</sup>은 자동 변조 분류를 위해 시간과 주파수 영역을 나타내는 2차원 분포 함수를 통해 이미지로 변환시켜 CNN의 입력값으로 사용하였다. 여기서 적용된 CNN은 ResNet152 모델을 Fine-Tuning 하여 사용하였으며 다수의 모델에서 특징값을 융합하여 8개 변조 방식에 대한 우수한 성능을 나타내었다. 하지만 적용된 ResNet152 모델은 신경망의 깊이가 깊으며 사용되는 파라미터도 깊이에 비례하여 증가하는 단점을 가진다. F. Meng, et al.<sup>[12]</sup>은 최대 우도추정 방식과 심층 CNN 방식과 비교하여 자동 변조 분류에 대한 성능을 나타내었으며 4개의 변조 방식에 대해 심층 CNN 방식의

성능이 더 우수함을 보였다. 하지만, 제안된 CNN 구조는 입력 데이터를 패딩을 통해 차원 수를 확장 시켰을 뿐 아니라 많은 연산량을 요구하는 필터(12×3, 24×3, 32×3)×2를 사용하여 모델의 비효율적인 구조를 가진다. S. Hong, et al.<sup>[13]</sup>는 경량화된 CNN 구조를 적용하여 기존의 CNN과 의사결정트리, SVM (Supporter Vector Machine) 등과 비교하여 자동 변조 분류에 대한 우수한 성능을 나타내었다. 하지만, 비교되는 변조 방식 가지 수가 부족하며 앞에서 언급된 논문에서 나타내는 성능을 유지하지 못하고 있다.

본 논문은 기존의 CNN 구조에서 연산되는 파라미터 수를 줄여 경량화된 CNN 모델을 설계하였고, 제안된 모델 구조는 ResNet 구조를 Fine-Tuning 한 구조를 가진다. 경량화를 위해 SqueezeNet 구조에서 1x1 합성곱 층과 3x3 합성곱 층을 조합하여 사용하였다. 제안된 CNN 구조의 성능을 분석하기 위해 DEEPSIG DATASET: RADIOML 2018.01A<sup>[14]</sup> 데이터셋을 사용하였으며, 사용된 데이터셋은 24개의 변조 방식에 대한 신호를 SNR -10dB에서 20dB까지 제공하며 제안된 CNN 모델에서의 자동 변조 분류 성능이 기존의 CNN 모델보다 우수한 것을 나타내었다.

본 논문의 구성은 다음과 같다. II장에서는 시스템 모델에 대해 소개하고, III장에서는 딥러닝 기반 자동 변조 분류에 대해 설명하였다. IV장에서는 제안된 기법에 대한 모의실험 및 성능분석에 대해 나타내었으며, 마지막으로 V장에서 결론 및 향후 연구에 대해 언급하였다.

## II. 시스템 모델

본 논문에서 신호의 자동 변조 분류를 위해 사용된 신호는 USRP B210 모델에서 생성된 신호를 사용하였으며 신호를 전송하기 위한 시스템 모델은 그림 1과 같다. 신호는 한 프레임당 총 1024 샘플 신호로 구성되며 생성 조건은 중심주파수 900MHz의 ISM 대역을 사용하였으며 송수신기 간의 클럭 오프셋은 어플리케이션에 사용되는 중심주파수를 변형과 샘플링 주파수 변형을 일으키는 요소로 정규분포  $N(0, \sigma_{clk})$  값을 가지며  $\sigma_{clk}$ 는 1ppm (parts per million)의 값을 가진다. 그리고 Roll-Off 인자는 균등 분포  $U(0.1, 0.4)$ 에서 값을 가진다. 무선 통신 시스템의 채널은 레일리 페이딩 환경을 가지며 여기서 지연확산은  $\tau = [0, 0.5, 1.0, 2.0]$ 로 설정되었다. 수신기에  $l$ 번째 수신된 신호는 다음같이 표현할 수 있다.

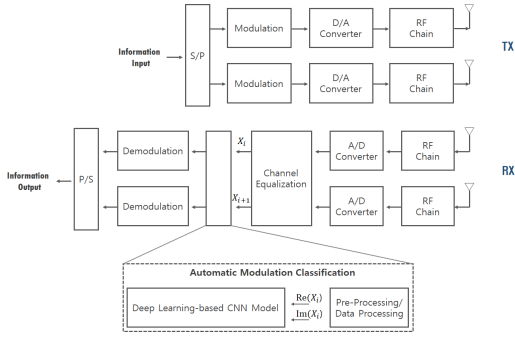


그림 1. 자동 변조 분류를 위한 시스템 모델 예시  
Fig. 1. Example of the system model for automatic modulation classification

$$\begin{aligned} y_1(l) &= h_{11}(l)x_1(l) + h_{12}(l)x_2(l) + n(l), \\ y_2(l) &= h_{21}(l)x_1(l) + h_{22}(l)x_2(l) + n(l), \end{aligned} \quad (1)$$

여기서  $y_1, y_2$ 는 각각의 안테나에 수신되는 신호를 의미하며  $h_{21}$ 은 두 번째 송신기와 안테나와 첫 번째 수신기 안테나 경로의 채널 이득을 의미하며  $x$ 는 기저대역 신호를 의미하고,  $n$ 은 백색 가우시안 잡음을 나타낸다. 채널 이득은 아래의 식으로 나타낼 수 있다.

$$h(l) = \alpha(l)e^{j(2\pi TRIANGLEfl + \Delta\phi(l))}, \quad (2)$$

여기서  $\alpha$ 은 송신기와 수신기 사이의 채널 임펄스 응답을 나타내며,  $\Delta f$ 와  $\Delta\phi$ 는 캐리어 주파수와 위상의 오프셋을 의미한다. 수신된 신호는 페이딩 채널 환경에서 손실된 신호를 보상하고 덤퍼닝 기반 자동 변조 분류 모델로 전달된다.

### III. 딥러닝 기반 자동 변조 분류

#### 3.1 전처리/데이터처리

딥러닝 기반 자동 변조 분류는 전처리/데이터처리와 딥러닝 기반 CNN 모델로 구성되며 전처리/데이터처리에서는 보상된 신호를 전달받아 신호를 정규화하고 CNN 모델의 입력값으로 사용하기 위해 실수부 (In-phase component)와 허수부 (Quadrature component)로 신호를 재정렬하여 고차원 행렬로 변환시킨다. 전달된 신호( $s_i$ )는 데이터처리 블록에서 제곱평균 제곱근 (RMS; Root Mean Square)을 통한 신호를 정규화한다. 이를 통해 신호 값의 범위를 재조정하여 경사 하강법을 통한 손실 함수의 기울기 값이 지역 최적

값이 아닌 전역 최적값을 가지도록 유도한다. 신호 정규화를 위한 식은 아래와 같다.

$$\begin{aligned} \bar{s}_i &= \frac{s_i}{RMS(s)}, \\ \text{where } RMS(s) &= \sqrt{\frac{1}{N} \sum_{i=1}^N |s_i|^2}, \end{aligned} \quad (3)$$

여기서  $N$ 는 하나의 프레임에 속한 샘플수로 1024의 수를 가지며 총 프레임 수는 각각의 변조 방식마다 4096개 프레임 수를 훈련 및 시험 데이터로 사용하였다. 정규화 후 신호는 고차원 행렬  $2 \times N$ 으로 재정렬되며 아래의 식과 같이 표현할 수 있다.

$$S = \begin{bmatrix} \bar{s}_0^I & \bar{s}_1^I & \dots & \bar{s}_N^I \\ \bar{s}_0^Q & \bar{s}_1^Q & \dots & \bar{s}_N^Q \end{bmatrix}, \quad (4)$$

여기서 상위 인덱스  $I, Q$ 는 각각 실수부와 허수부를 의미하며, 행렬  $S$ 를 기반으로 프레임 수와 변조 방식에 따라 행렬  $H$ 로 아래의 식과 같이 표현할 수 있다.

$$H = \begin{bmatrix} S_{m,k} & S_{m,k+1} & \dots & S_{m,K} \\ S_{m+1,k} & S_{m+1,k+1} & \dots & S_{m+1,K} \\ \vdots & \vdots & \ddots & \vdots \\ S_{M,k} & S_{M,k+1} & \dots & S_{M,K} \end{bmatrix}, \quad (4)$$

여기서 인덱스  $M$ 은 총 프레임 수를 의미하며  $K$ 는 총 변조 방식 수를 의미한다.

#### 3.2 CNN 모델

CNN은 인공신경망 중 한 종류로 센서 데이터 및 이미지 데이터 입력값을 학습하여 분류<sup>[11-14]</sup> 및 회귀<sup>[16]</sup>에 대한 결과를 나타내며, 또 우수한 학습 성능을 가진다. 본 논문에서 사용되는 CNN은 분류를 위한 목적으로 사용되며 제안하는 CNN 모델에서  $\kappa$ 번째 특징맵( $z$ )을 나타내기 위해 합성곱 층을 사용하며 아래의 식과 같이 나타낼 수 있다.

$$z_\kappa = \sum_{d=1}^d \sum_{q=1}^q \sum_{p=1}^p (F_{d,q,p} \times X_{d,q,p}) + b_d \quad (5)$$

여기서  $d, q, p$ 는 각각 필터 수, 세로, 가로 인덱스를 의미하며  $F$ 는 합성곱에 사용되는 필터이고,  $X$ 는 입력값, 그리고  $b$ 는 바이어스 값이며 필터 수에 따라

크기가 결정된다. 합성곱 계층을 통해 나온 특징맵은 배치 정규화 층을 통해 특징값을 정규화하며 이는 아래의 식과 같이 나타낼 수 있다.

$$\hat{z}'_{\kappa} = \frac{z_{\kappa} - \mu_B}{\sqrt{\sigma_B^2 + \rho}}, \quad (6)$$

$$\text{where, } \sigma_B^2 = \frac{1}{\kappa} \sum_{\kappa=1}^{\kappa} (z_{\kappa} - \mu_B)^2$$

여기서  $\mu_B$ 는 최소 배치의 평균값이며  $\sigma_B^2$ 는 최소 배치의 분산값을 의미하고, 그리고  $\rho$ 는 분모가 0이 되지 않도록 주어지는 매우 작은 값으로 임의로 지정된다. 배치 정규화된 출력값은 활성화 함수를 통해 다음 층으로 값을 전달할지를 결정하게 되며 제안된 모델에서는 ReLU (Rectified Linear Units) 함수를 사용하였고 아래의 식과 같이 나타낼 수 있다.

$$f(z'_{\kappa}) = \begin{cases} 0, & \text{if } z'_{\kappa} < 0, \\ z'_{\kappa}, & \text{otherwise,} \end{cases} \quad (7)$$

마지막으로 완전 연결 계층을 통해 전달된 값은 Softmax 계층을 통해 클래스 별로 정답일 확률을 부여하고 아래의 식을 통해 나타낼 수 있다.

$$\rho_{softmax}(z'_{\kappa}) = \frac{e^{z'_{\kappa}}}{\sum_{\kappa} e^{z'_{\kappa}}} \quad (8)$$

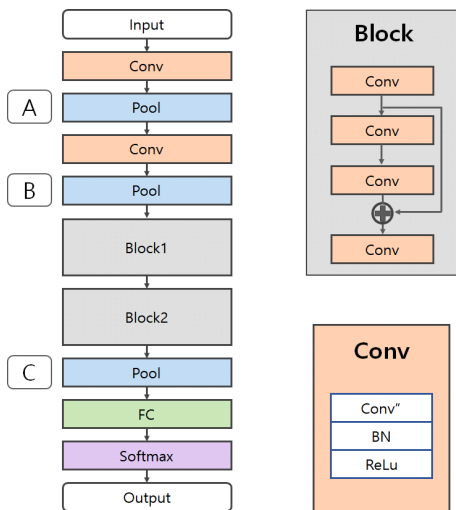


그림 2. 제안된 경량 DCNN 구조  
Fig. 2. The proposed light-weight DCNN structure

제안하는 모델은 SGDM (Stochastic Gradient Descent with Momentum) 최적화 기법을 사용하여 손실 값을 최적화하였으며, 여기서 사용되는 가중치 ( $w$ )는 아래와 같이 나타낼 수 있다.

$$v_{t+1} := \alpha v_t - \eta \nabla Q(w_t),$$

$$\text{where, } Q(w_t) = \frac{1}{L} \sum_{t=1}^L (\hat{y}_t - y_t)^2 \quad (9)$$

$$w_{t+1} := w_t + v_{t+1}, \quad (10)$$

여기서  $v$ 는 중간 가중치 값으로 각각의 반복 학습 때마다 사용되며 가중치( $w$ )와 선형조합을 통해 갱신된다.  $\alpha$ 는 모멘트 계수이며,  $\eta$ 는 학습률을 나타내고,  $\hat{y}$ 는 추정값, 그리고  $y$ 는 참값을 나타낸다.

### 3.3 제안된 경량 CNN 모델

제안된 모델은 그림2와 같으며 그림에서 나타낸 바와 같이 합성곱 계층을 통해서 여러 개의 은닉층을 만들어 내며 풀링 계층을 통해 은닉층의 특징맵 차원 크기를 축소하고 완전 연결 계층과 Softmax 계층을 통해 최종 분류 계층으로 결과가 판정되는 순서로 진행된다. 여기서 합성곱 계층은 합성곱 계층과 배치 정규화 계층과 ReLU 활성화 함수 계층으로 구성되었으며, 풀링 계층의 필터 크기 조정하였을 때 제안된 모델과의 예측 정확도 성능을 비교분석 하였다.

입력층은 1024샘플을 실수부와 허부수로 구분하여  $2 \times 1024$ 의 크기를 가지며 다음 합성곱 계층에서 패딩을 통해 행의 크기를 6으로 증가시킨 후  $3 \times 3$  필터를 적용하였다. 다음 풀링 계층을 통해 입력 크기를 줄이고 처음 합성곱 계층과 동일한 작업을 다음 합성곱 계층에서 수행한다. 여기서 제안된 모델에서 풀링 계층은 모두 평균 풀링 계층을 적용하였으며 stride는 필터 크기와 동일하다. 그리고, 풀링 계층을 통해 특징맵의 축소되는 면적에 따라 정확도 성능에 영향을 가진다. 풀링 계층을 통한 다운 샘플링 후 Block1으로 특징맵이 입력된다. Block은 보틀넥 구조로 설계하여 point-wise 합성곱 연산을 통해 일반적인 구조보다 연산량을 줄이도록 하였다. 여기서 Block1, 2에서  $3 \times 1$ ,  $1 \times 3$  합성곱 계층으로 나누어 사용하는 것이  $3 \times 3$  합성곱 계층 하나를 사용하는 것보다 Block1에서 11k 파라미터를 줄일 수 있으며, Block2에서 36k 파라미터를 줄이는 효과를 가진다. 추가로,  $1 \times 1$  합성곱 계층을  $3 \times 3$  합성곱 계층으로 사용하였을 때

표 1. 경량 합성곱 신경망 모델 구조 설명  
Table 1. The description of proposed CNN model.

| Type    | Filter Size                                | Output Size                                       | Parameters |
|---------|--|---|------------|
| Input   | -  | 2×1024  | -          |
| Conv    | 3×3×16                                     | 6×1024×16   | 192        |
| Pool    | 4×2  | 2×512×16  | -          |
| Conv    | 3×3×32                                     | 6×512×32  | 4704       |
| Pool    | 4×2  | 2×256×32  | -          |
| Block1  | 1×1×64,<br>3×1×48,<br>1×3×48,<br>1×1×64,   | 2×256×64,<br>2×256×48,<br>2×256×48,<br>2×256×64   | 21,920     |
| Block2  | 1×1×128,<br>3×1×64,<br>1×3×64,<br>1×1×128, | 2×256×128,<br>2×256×64,<br>2×256×64,<br>2×256×128 | 54,400     |
| Pool    | 2×256                                      | 1×1×128   | -          |
| FC      | -  | 24×128  | 3,096      |
| Softmax | -  | 24  | -          |
| Output  | -  | -   | -          |
| Total   | -  | -   | 84,312     |

사용되는 파라미터는 Block1에서 52k, Block2에서 167k 더 많은 파라미터를 사용하는 것을 알 수 있다. 다음 skip connection 구조를 적용하여 정보손실을 줄이도록 하였다. 여기서 skip connection은 배치 정규화 다음 더하기 연산이 수행되도록 하였다. 마지막 풀링 계층에서 2×256 특징맵 크기를 1×1으로 줄여 완전 연결 계층으로 전달하였으며 완전 연결 계층에서는 24개의 클래스로 출력하여 Softmax 계층으로 전달한다. 24개의 클래스는 아래와 같이 구분할 수 있다.

- Low Order Classes: OOK, BPSK, AM-SSB-SC, AM-DSB-SC, AM-SSB-WC, AM-DSB-WC, FM
- High Order Classes: 4ASK, 8ASK, QPSK, OQPSK, 8PSK, 16PSK, 32PSK, 16APSK, GMSK, 32APSK, 64APSK, 128APSK, 16QAM, 32QAM, 64QAM, 128QAM, 256QAM

IV. 모의실험 및 성능분석

본 논문에서 제안된 모델의 모의실험은 각 클래스별로 4096개의 프레임을 적용하여 총 98304개의 프레임을 사용하였으며 여기서 80%는 학습 데이터로 20%는 시험 데이터로 사용하였다. 모의실험을 위한

표 2. DCNN 모의실험 설정  
Table 2. The configuration of DCNN simulation.

| Type                | Value |
|---------------------|-------|
| MaxEpochs           | 45    |
| MiniBatchSize       | 64    |
| InitialLearnRate    | 0.002 |
| LearnRateDropPeriod | 35    |
| LearnRateDropFactor | 0.05  |

해석 프로그램은 Matlab 2019b를 사용하였으며 하드웨어 장비는 CPU i5-9400F, RAM 32GByte, GPU NVIDIA RTX 2080 SUPER를 사용하였다. 모의실험을 위한 설정은 표 2와 같으며 제안된 모델과 성능 비교를 위하여 VGG<sup>[17]</sup>, ResNet<sup>[17]</sup>와 비교하여 SNR에 따라 성능을 나타내었으며 제안한 모델이 기존의 모델보다 적은 파라미터를 사용한 것 대비 우수한 성능을 보였다. 그림 3은 0 - 20 dB SNR 구간에서 각 모델의 예측 정확도 성능을 나타내었으며 제안된 모델이 다른 모델보다 전 구간에서 우수한 성능을 가지며, SNR 0 dB에서 VGG 50.82%, ResNet 50.12%, AMC-CNN 29.49% 그리고 제안된 모델 55.89%로 최대 26% 이상 높은 성능을 가지며, SNR 10dB에서는 VGG 78.96%, ResNet 80.39%, AMC-CNN 60% 그리고 제안된 모델 91.59%로 최대 31% 이상 향상된 성능을 가지고, SNR 20 dB에서는 VGG 83.76%, ResNet 82.53%, AMC-CNN 67.86% 그리고 제안된 모델 94.57%로 최대 25% 이상 성능 차이를 가진다. 여기서 AMC-CNN은 4가지 클래스를 구별하는 경량 모델로 설계되었으며 24개의 클래스를 예측하는 성능은 다른 모델보다 전체적으로 크게 낮은 것을 볼 수




그림 3. 테스트셋을 통한 예측정확도 성능 비교  
Fig. 3. Predicted performance comparison by the testset




그림 4. 풀링 계층 필터 크기에 따른 예측정확도 성능 비교  
Fig. 4. Predicted performance comparison by pooling layer filter size

있다. 따라서 초기에 정해진 데이터셋에 따라 네트워크를 설계하는 것이 중요함을 알 수 있다.

그림 4는 제안된 모델에서 사용된 풀링 계층의 필터 크기를 조절하였을 때 예측 정확도를 나타내었다. 필터 크기가 조정된 풀링 계층은 그림 2의 A, B 지점에 위치한 풀링 계층의 필터 크기를 동시에 4×4로 변경하였을 때 그리고 4×8로 변경하였을 때 예측 정확도를 나타내었으며, 필터 크기가 커질수록 예측 정확도 성능이 낮아지는 것을 결과를 통해 볼 수 있다. 이를 통해 풀링 계층의 필터 크기에 따라 제안된 모델의 예측성능에 큰 차이를 나타내는 것을 알 수 있다.

그림 5와 6에서는 예측하기 어려운 고차 변조 방식을 주로 나타내었으며 그림 5에서는 제안된 모델을 통한 QAM 변조 방식의 예측 정확도를 나타내었으며




그림 5. 제안된 모델의 QAM 변조 방식 성능 비교  
Fig. 5. Performance comparison among QAM by proposed model




그림 6. 제안된 모델의 ASK/PSK 변조 방식 성능 비교  
Fig. 6. Performance comparison among ASK/PSK by proposed model

SNR이 증가할수록 64와 256 QAM을 제외하고 성능이 좋아짐을 볼 수 있으며 64 QAM의 경우 AM-SSB-WC 변조 방식을 주로 예측함을 통해 거짓 양성 비율이 높았으며, 256 QAM은 QPSK 변조 방식을 주로 예측하여 이에 대한 거짓 양성 비율이 높게 나왔다.

그림 6은 제안된 모델에서 ASK/PSK 변조 방식의 예측 정확도를 나타내었으며 SNR이 증가할수록 전체적으로 예측성능이 향상되었으며 SNR 10 dB에서는 128 APSK를 제외한 나머지 변조 방식은 90% 이상을 예측정확도를 가지는 것을 볼 수 있다. 낮은 SNR 영역에서 4 ASK는 8 PSK를 주로 거짓 양성으로 예측하였으며, 8 ASK는 OQPSK, 16 APSK는 32 QAM, 32 APSK는 8 ASK, 64 APSK는 BPSK, 그리고 AM-SSB-SC 변조 방식을 주로 거짓 양성으로 각각 예측하였다.

그림 7과 8에서는 SNR 10 dB와 0 dB에서 전체적인 변조 방식에 대한 직관적 예측 정확도 분석을 위하여 시각화하여 나타내었으며 낮은 SNR으로 진행될수록 BPSK, GMSK와 같이 일반적 변조 방식보다 ASK, APSK 등의 고차 변조 방식을 예측 정확도가 낮아지는 것을 볼 수 있다.

표 3은 각 모델의 계산복잡도 성능에 대해 나타내었으며 제안된 모델에서 사용된 파라미터 수는 84K로 다른 모델 VGG (257K), ResNet (236K) 보다 각각 67.3%, 64.4% 경량화하였으며 예측 시간도 1 프레임 당 VGG 보다 47.5%, ResNet 보다 33.3% 예측 시간이 빠르며 예측 정확도 역시 더 우수함을 볼 수 있다. 추가로, AMC-CNN (27K)는 제안된 모델보다 67.8%






그림 7. SNR 10 dB, 91.59% 예측 정확도에 대한 분류결과 표  
 Fig. 7. Confusion matrix for accuracy 91.59% at SNR 10 dB

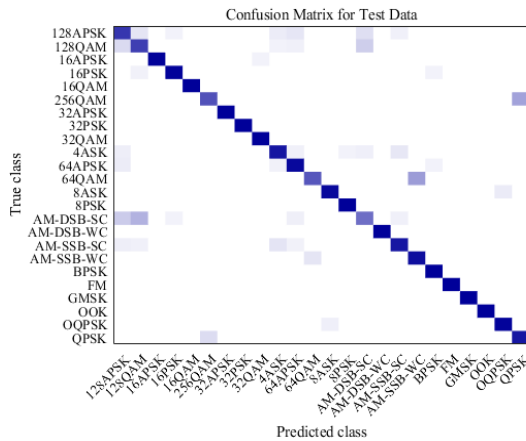


그림 8. SNR 10 dB, 91.59% 예측 정확도에 대한 분류결과 표  
 Fig. 8. Confusion matrix for accuracy 91.59% at SNR 10 dB

표 3. 각 모델의 복잡도 비교  
 Table 3. Computation complexity of each model.

| Model          | Number of Parameters | Predicted Time Consumption [ms] |
|----------------|----------------------|---------------------------------|
| VGG[17]        | 257K                 | 0.1279                          |
| ResNet[17]     | 236K                 | 0.1006                          |
| AMC-CNN[12]    | 27K                  | 0.0485                          |
| Proposed Model | 84K                  | 0.0671                          |

적게 사용하였지만 제안된 모델보다 SNR 0 dB에서 26%, 10 dB에서 31% 매우 낮은 예측 정확도를 가지

는 것을 볼 수 있다. 따라서, 전체적으로 제안된 모델의 다른 모델보다 성능이 우수함을 볼 수 있다.

### V. 결론 및 향후연구

본 논문에서는 인지 무선 기술에서 자동 변조 분류를 수행하기 위하여 경량 합성곱 신경망 모델을 제안하였다. 제안된 모델은 ResNet의 skip connection 구조를 적용을 통해 vanishing gradient 문제를 최소화하였으며, 병목 구조 형태로 설계함으로 일반적인 합성곱 신경망 모델보다 연산량을 적게 하였다. 제안된 모델을 통한 특징 추출을 하기 위해 입력 데이터 동기화와 정규화 그리고 고차원으로 데이터 재구성을 하였으며, 성능 평가를 위하여 24개의 변조 방식을 가지는 데이터셋을 사용하여 기존의 심층 학습 네트워크인 ResNet과 VGG 그리고 AMC-CNN의 정확도 성능 및 예측 시간을 비교하였다. 모의실험을 통해 제안된 모델의 성능이 기존의 모델보다 전체 SNR 영역에서 예측 정확도 성능이 우수한 것을 확인하였으며, 특히 SNR 10 dB에서 최대 31.59% 이상 높은 정확도를 보였다. 입력 신호를 예측하는 시간 또한, 최대 47.5% 이상 기존 모델보다 빠르게 예측하는 것을 확인하였다. 향후 연구로는 SNR이 낮은 영역에서도 정확도를 높이기 위해 특징 추출에 기법에 대한 연구를 진행할 예정이다.

### References

- [1] T. T. Le and D. S. Kim, "An efficient throughput improvement through bandwidth awareness in cognitive radio networks," *J. Commun. and Netw.*, vol. 16, no. 2, pp. 146-154, Apr. 2014.
- [2] Y. Gao, Z. Qin, Z. Feng, Q. Zhang, O. Holland, and M. Dohler, "Scalable and reliable IoT enabled by dynamic spectrum management for M2M in LTE-A," *IEEE Internet Things J.*, vol. 3, no. 6, pp. 1135-1145, Dec. 2016.
- [3] S. H. Kim, K. H. Kwon, J. W. Kim, and D. S. Kim, "Efficient channel handoff scheme for cognitive-radio-based industrial internet of things," *J. KICS*, vol. 44, no. 9, pp. 1658-1665, Sep. 2019.
- [4] Y. Wang, M. Liu, J. Yang, and G. Gui,

- “Data-driven deep learning for automatic modulation recognition in cognitive radios,” *IEEE Trans. Veh. Technol.*, vol. 68, no. 4, pp. 4074-4077, Apr. 2019.
- [5] F. Hameed, O. A. Dobre, and D. C. Popescu, “On the likelihood-based approach to modulation classification,” *IEEE Trans. Wirel. Commun.*, vol. 8, no. 12, pp. 5884-5892, Dec. 2009.
- [6] S. U. Pawar and J. F. Doherty, “Modulation recognition in continuous phase modulation using approximate entropy,” *IEEE Trans. Info. Forensics and Secur.*, vol. 6, no. 3, pp. 843-852, Sep. 2011.
- [7] A. Swami and B. M. Sadler, “Hierarchical digital modulation classification using cumulants,” *IEEE Trans. Commun.*, vol. 48, no. 3, pp. 416-429, Mar. 2000.
- [8] H. Wu, M. Saquib, and Z. Yun, “Novel automatic modulation classification using cumulant features for communications via multipath channels,” *IEEE Trans. Wirel. Commun.*, vol. 7, no. 8, pp. 3098-3105, Aug. 2008.
- [9] D. Boutte and B. Santhanam, “A hybrid ICA-SVM approach to continuous phase modulation recognition,” *IEEE Signal Process. Lett.*, vol. 16, no. 5, pp. 402-405, May 2009.
- [10] S. H. Kim, K. H. Kwon, J. W. Kim, and D. S. Kim, “Analysis and application trend of machine learning technology to improve the performance of wireless sensor networks,” *J. KICS*, vol. 45, no. 1, pp. 61-79, Jan. 2020.
- [11] Z. Zhang, C. Wang, C. Gan, S. Sun, and M. Wang, “Automatic modulation classification using convolutional neural network with features fusion of SPWVD and BJD,” *IEEE Trans. Signal and Info. Process. over Netw.*, vol. 5, no. 3, pp. 469-478, Sep. 2019.
- [12] F. Meng, P. Chen, L. Wu, and X. Wang, “Automatic modulation classification: A deep learning enabled approach,” *IEEE Trans. Veh. Technol.*, vol. 67, no. 11, pp. 10760-10772, Nov. 2018.
- [13] A. Ali and F. Yangyu, “Automatic modulation classification using deep learning based on sparse autoencoders with nonnegativity constraints,” *IEEE Signal Process. Lett.*, vol. 24, no. 11, pp. 1626-1630, Nov. 2017.
- [14] M. Zhang, M. Diao, and L. Guo, “Convolutional neural networks for automatic cognitive radio waveform recognition,” *IEEE Access*, vol. 5, pp. 11074-11082, 2017.
- [15] <https://www.deepsig.io/datasets>
- [16] K. Chen and W. Tao, “Learning linear regression via single-convolutional layer for visual object tracking,” in *IEEE Trans. Multimedia*, vol. 21, no. 1, pp. 86-97, Jan. 2019.
- [17] T. J. O’Shea, T. Roy, and T. C. Clancy, “Over-the-air deep learning based radio signal classification,” *IEEE J. Sel. Topics in Signal Process.*, vol. 12, no. 1, pp. 168-179, Feb. 2018.

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~현재 : ICT융합특성

화연구센터 전임연구원

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

[ORCID:0000-0002-4118-8703]

김 치 윤 (Chi-Yoon Kim)



2019년 2월 : 금오공과대학교 전  
자공학부 졸업  
2019년 3월~현재 : 금오공과대  
학교 전자공학과 석사과정  
<관심분야> 기계학습, 심층 인공  
신경망, 3D 프린팅



유 상 호 (Sang-Ho Yoo)



2018년 8월 : 금오공과대학교 전  
자공학부 졸업  
2020년 8월 : 금오공과대학교 IT  
융복합공학 석사 졸업  
<관심분야> 기계학습, 심층 인공  
신경망, 네트워크 가상화

김 등 성 (Dong-Seong Kim)



1992년 2월 : 한양대학교 전자공  
학과 졸업  
2003년 3월 : 서울대학교 전기  
및 컴퓨터공학부 박사졸업  
2004년 : Cornell 대학교 ECE 박  
사 후 연구원  
2004년 3월~현재 : 금오공대 전  
자공학부 정교수

2019년~현재 : 금오공과대학교 산학협력단 단장  
2014년~현재 : ICT융합특성화연구센터 센터장  
(과학기술정보통신부 Grand ICT 및 연구재단 중점연구소)  
2014년~현재 : IEEE/ACM Senior 회원  
2015년~2018년 : 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]