

확장된 프레임을 적용한 딥러닝 기반 자동 변조 분류 설계

김승환*, 문창배*, 김재우*, 김동성^o

Design of Automatic Modulation Classification Based on Deep Learning Technique Applying Extended Frame

Seung-Hwan Kim*, Chang-Bae Moon*, Jae-Woo Kim*, Dong-Seong Kim^o

요약

본 논문에서는 인지 통신망에 적용되는 핵심 기술인 자동 변조 분류를 위해 새로운 방식의 딥러닝 기반 자동 변조 분류 기법을 제안하였다. 제안된 모델은 Convolutional Neural Network (CNN) 방식을 통해 설계되었으며 기울기값이 사라지는 문제를 완화하여 정확도를 높이기 위해 ResNet의 스킵커넥션 구조를 적용하였고 또 네트워크의 계산 복잡도를 줄이기 위해 비대칭 컨볼루션 필터 구조를 적용하였다. 일반적으로 CNN 기반 자동 변조 분류는 복소 신호를 실수성분과 허수성분으로 분리하여 $2 \times N$ 크기의 입력값이 사용되지만, 본 논문에서는 송신기로부터 받은 복소 신호를($2 \times N$)을 $4 \times N$ 로 확장하여 적용하였다. 프레임의 확장 방식은 기존의 수신된 프레임을 복사하여 수평적으로 순서를 역으로 바꾸어서 기존의 프레임에 연결하는 방법이다. 제안된 방법을 통한 CNN 모델의 성능 평가를 위하여 24개의 변조 방식을 가지는 DeepSig:RadioML 2018.01A 데이터셋을 사용하였으며 자동 변조 분류를 위한 최신 딥러닝 모델인 ResNet, MCNet 그리고 LCNN과 비교하여 검출확률의 성능 및 계산 복잡도를 비교분석하였다. 시뮬레이션 결과를 통해 제안된 모델이 기존의 모델보다 전 구간 SNR (Signal-to-Noise Ratio) 영역에서 검출확률 성능이 우수한 것을 확인하였으며, 특히 SNR 10 dB에서 최소 2.5% 이상 높은 검출확률을 보였다.

Key Words : Automatic Modulation Classification, Convolutional Neural Network, Cognitive Radio Network, Frame Extension, Predicted Accuracy

ABSTRACT

In this paper, a new deep learning-based automatic modulation classification technique is proposed for automatic modulation classification that is applied to cognitive radio networks. The proposed model is designed by Convolutional Neural Network (CNN) technique, which contains skip connection structure of ResNet to minimize the vanishing gradient problem and convolutional layers with asymmetric kernels to reduce computation complexity. In general, complex signals are divided into $2 \times N$ to utilize as input size of the CNN. However, in this paper, by extending the kept frame from a transmitter $4 \times N$ size is adopted for the proposed CNN. For the frame extension method there are three steps. First, the present frame is copied.

* 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, 정희원

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

* Kumoh National Institute of Technology, ICT Convergence Research Center, cb.moon@kumoh.ac.kr; jaewookim@kumoh.ac.kr, 정희원
논문번호 : 202101-017-RN.R1, Received January 15, 2021; Revised March 23, 2021; Accepted March 23, 2021

Second, the order horizontally is reversed. Finally, it is connected to the existing frame. To evaluate the performance of the proposed CNN model the DeepSig:RadioML 2018.01A dataset with 24 modulation schemes was used, and the accuracy performance and the computational complexity are compared to the latest deep learning models ResNet, MCNet and LCNN. Through the simulation results, the proposed model has better prediction accuracy performance in the entire signal-to-noise ratio (SNR) region than the conventional model, where it showed at least 2.5% higher accuracy at SNR 10 dB.

1. 서 론

사물인터넷과 같은 무선 통신 기술의 발달 및 항공, 물류, 에너지 등의 산업응용 분야에 적용과 스마트폰 등의 휴대용 무선통신기기 보급 확산 및 사용량 증가로 인해 가용주파수 자원에 대한 요구가 계속해서 늘어나고 있다^{1,2}. 또한 제한적인 주파수 자원으로 다양한 응용 분야별로 안정적인 서비스를 제공에 어려움이 발생하고 있다^{3,4}. 따라서, 제한적인 주파수 자원에 대한 사용 효율성을 높이기 위해 사용되지 않는 주파수를 인지하여 사용하게 하는 인지 통신 기술이 제안되었다⁵.

인지 통신 기술은 주 사용자가 사용하는 채널을 부 사용자가 주 사용자에게 간섭을 주지 않는 범위 내에서 채널을 감지하여 해당 채널을 사용하는 기술이다. 주 사용자를 제외한 부 사용자의 경우 채널에 접근하여 데이터를 전송할 때 각각 다른 유형의 변조 방식을 통해 전송할 수 있으므로 정확한 변조 방식을 인지하고 해당 변조 방식으로 복조하는 기법이 인지 통신에 있어서 매우 중요하다. 따라서, 자동적으로 변조 유형을 선택하는 자동 변조 분류 기법이 제안되었으며, 이 기법은 신호에 대한 사전지식 없어도 자동적으로 신호의 변조 유형을 식별하게 한다⁶.

기존의 자동 변조 분류 기법은 2가지 종류로 제안되었으며, 첫 번째는 최대 우도추정 기반의 의사결정 이론 방식이 있으며 두 번째는 특징 기반의 패턴인식 방식이다. 최대 우도추정 방식은 베이저안 추론을 통해 사전확률과 사후확률을 구분하여 최적의 값을 얻게 되는 최적의 방식이지만 사전확률을 얻기 위한 충분한 사전 데이터 확보와 채널 상태에 대한 완전한 정보를 가져야 하는 전제 조건이 따른다. 또한 신호의 정확한 변조 분류 확률을 연산하기 위해 높은 계산 복잡도가 발생함으로 현실적으로 구현이 어려운 단점을 가진다.

특징 기반의 패턴인식 방식은 3단계로 구분하여 신호를 판별한다. 첫 번째는 입력 데이터 전처리, 그리고 특징 추출, 마지막으로 분류 결정으로 나누어진다.

특징 추출 기반 방식의 전처리는 특징추출 단계에서 정확한 특징을 추출할 수 있도록 데이터를 사전 가공하는 단계이며 수집된 데이터의 샘플링과 동기화, 노이즈 제거, 정규화 등을 수행한다. 특징추출에서는 사전 가공된 데이터를 순간 특징, 순환정지 특징, 고차 큐물런트 특징 등 다양함 방식 중 하나를 선택하여 특징을 추출하는 단계이다. 마지막으로 분류 결정에서는 먼저 분류기를 선정하여 추출된 특징을 적용하여 판별하는 단계로 주로 사용되는 서포트벡터머신(SVM), 최근접 이웃 알고리즘(k-NN), 의사결정트리(DT) 등을 포함하여 많은 분류기가 사용된다. 특징 기반 인지 방식은 최대 우도추정 방식보다 성능 부분에서 우수하지는 않음에도 낮은 계산 복잡도와 구현이 용이한 장점으로 실제적으로 적용되어진다. 반면에 일부 특징 추출 방법 중 고차 큐물런트의 경우 블라인드 신호를 식별하기 위해 사용되는 효과적인 방식이지만, M-QAM, M-PSK 등 고차 변조를 적용한 신호를 해석하기 위해 계산 복잡도가 증가할 수 있다. 또한 매 뉴얼적 특징을 적용시 각 변조의 깊은 특징의 정보를 손실되는 가능성이 있다⁷. 게다가 기존의 머신러닝 분류기 역시 입력되는 특징에 의존적임으로 분류되는 결과 정확도 역시 한계를 가지게 된다.

최근 기존의 특징 기반 인지 방식의 한계점을 뛰어넘는 딥러닝 기반 인지 방식이 제안⁸되었으며 그 중 합성곱 신경망(CNN) 기법의 우수성을 초기 응용분야^{9,10} 뿐만 아니라 자동 변조 분류 분야^{4,11-13}에서 또한 나타내었다. H. Thien, et al.¹⁴에서는 24개 변조 타입을 포함하는 DeepSig 최신 데이터셋을 사용하여 CNN 모델을 설계하였다. 프레임 길이를 128, 256, 512 그리고 1024 길이로 조정하여 각 성능에 대해 나타내었으며, 프레임 길이 1024, SNR 10 dB에서 약 88% 분류성능을 나타내었다. T. Huynh The, et al.¹¹은 24가지 변조 타입에 대한 경량 MCNet 모델을 설계하였으며 네트워크 깊이에 따른 정확도 성능과 각 변조 타입에 대한 예측 성능을 나타내었으며 기존 모델 대비 정확도 및 계산 복잡도 부분에서 우수성을 나타내었다. S. Hong, et al.¹²은 신호의 중요 특징을 추출

하기 위해 다중 스트림 CNN 구조를 설계하여 11개의 변조 타입에 대한 성능을 나타내었다. 또한 다중 스트림에 적용된 블록에 따라서 예측성능 추세를 나타내어 모델을 설계할 최적의 구조 선택이 가능하다. 마지막으로 H. Gu, et al.^[13]는 LoS(Line of Sight) 그리고 Non-LoS 채널을 식별하고 변조 타입을 학습하여 블라인드 채널의 상태에서 변조 타입을 식별하는 2개의 CNN 모델을 제안하였다. 제안된 모델은 채널을 식별 후 신호를 분류하여 블라인드 채널에서 신호를 식별하는 우수성을 나타내었다. 앞서 언급된 자동 변조 분류를 위한 CNN 모델의 공통점은 복소 신호를 실수부와 허수부로 구분하여 $2 \times N$ 로 입력을 가진다, 여기서 N 은 프레임의 길이를 나타낸다.

본 논문은 CNN 모델이 신호의 주요한 특징 추출하는 것을 높이기 위해 기존의 프레임 크기 $2 \times N$ 에서 $4 \times N$ 으로 확장^[14]하였으며 이를 CNN 모델의 입력으로 사용하였다. 프레임의 크기를 확장하여 계산 복잡도 역시 증가함으로 평균풀링 계층을 통해 특징 맵의 크기를 $2 \times N$ 로 압축되도록 설계하였다. 제안된 CNN 구조의 성능을 분석하기 위해 DEEPSIG DATASET: RADIOML 2018.01A^[15] 데이터셋을 사용하였으며, 여기서 SNR 0dB에서 20dB까지 2dB 간격으로 24개의 변조 타입에 대한 프레임은 포함하고 있다. 모의실험을 통해 제안된 CNN 모델의 자동 변조 분류성능이 기존의 CNN 모델보다 우수한 것을 나타내었다.

본 논문의 구성은 다음과 같다. II장에서는 시스템 모델에 대해 소개하고, III장에서는 제안된 딥러닝 모델에 대해 설명하였다. IV장에서는 제안된 기법에 대한 시뮬레이션 결과에 대해 나타내었으며, 마지막으로 V장에 결론 및 향후 연구에 대해 언급하였다.

II. 시스템 모델

2.1 시스템 모델

임의의 신호를 수신하여 식별하기 위한 딥러닝 기반 자동 변조 분류 과정을 그림 1에 나타내었으며, 여기서 송수신기에 각 2개의 안테나를 가지는 Multi-Input Multi-Output (MIMO) 시스템을 통해 데이터 전송이 이루어지고 변조타입은 정해진 24가지 중 하나를 수신하는 것으로 가정하였다. 또한 수신된 신호는 클럭오프셋으로 인한 주파수 오프셋과 위상 오프셋이 발생하며, Rayleigh 채널을 통과하면서 왜곡이 발생하는 것으로 하였다. 따라서, 수신기에서 임의의 신호를 수신할 때 아래의 식으로 나타낼 수 있다.




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

$$Y = HX + N. \tag{1}$$

여기서 Y 는 $[y_1, y_2 \dots y_N]$ 수신신호 벡터이며, H 는 $\begin{bmatrix} h_{11} & h_{12} \\ h_{21} & h_{22} \end{bmatrix}$ 채널 매트릭스, X 는 $[x_1, x_2 \dots x_M]$ 변조된 심볼 벡터 그리고 N 은 가산 백색 가우시안 잡음이다. N_t 와 N_r 는 송신기와 수신기의 안테나 수를 각각 의미한다. 채널 매트릭스에서 하나의 채널 계수는 아래의 식으로 나타낼 수 있다.

$$h = \alpha e^{j(2\pi f_\Delta t + \phi_\Delta)}. \tag{2}$$

여기서 α 은 송신기와 수신기 사이의 다중경로 진폭을 나타내며, f_Δ 와 ϕ_Δ 는 캐리어 주파수와 위상의 오프셋을 의미한다. 수신된 복소 신호는 전처리 단계로 들어가 데이터 가공이 수행하며 이때 Root Mean Square (RMS) 정규화를 처음으로 수행한다. RMS 정규화는 다음과 같이 나타낼 수 있다.

$$\bar{s}_i = \frac{s_i}{\sqrt{\frac{1}{N} \sum_{i=1}^N |s_i|^2}}. \tag{3}$$

여기서 s_i 는 프레임에서 하나의 요소를 나타내며 각 프레임의 길이 N 은 1024이다. 정규화된 프레임은 실수부 (In-phase component)와 허수부 (Quadrature component)로 나누어 2×1024 매트릭스로 구성하며 다음과 같이 나타낼 수 있다.

$$S = \begin{bmatrix} -I & -I & \dots & -I \\ s_0 & s_1 & \dots & s_{N-1} \\ -Q & -Q & \dots & -Q \\ s_0 & s_1 & \dots & s_{N-1} \end{bmatrix}. \tag{4}$$

여기서 상위 인덱스 I, Q는 각각 실수부와 허수부를 의미하며 프레임을 확장 및 적용하기 위해 S 매트

릭스를 복사하여 순서를 역으로 나열한 다음 S 매트릭스에 연결시킨다. 이는 4×1024 로 표현되며 아래와 같이 나타낼 수 있다.

$$\bar{S} = \begin{bmatrix} -I & -I & \cdots & -I \\ s_0 & s_1 & \cdots & s_{N-1} \\ -Q & -Q & \cdots & -Q \\ s_0 & s_1 & \cdots & s_{N-1} \\ -I & -I & \cdots & -I \\ s_{N-1} & s_{N-2} & \cdots & s_0 \\ -Q & -Q & \cdots & -Q \\ s_{N-1} & s_{N-2} & \cdots & s_0 \end{bmatrix}. \quad (5)$$

\bar{S} 매트릭스는 최종적으로 CNN 모델의 입력값으로 적용되어 데이터를 학습하게 된다. 변조 타입 수와 학습하기 위해 사용되는 프레임 수를 고려하여 아래의 식으로 나타낼 수 있다.

$$H = \begin{bmatrix} \bar{S}_{m,k} & \bar{S}_{m,k+1} & \cdots & \bar{S}_{m,K} \\ \bar{S}_{m+1,k} & \bar{S}_{m+1,k+1} & \cdots & \bar{S}_{m+1,K} \\ \vdots & \vdots & \ddots & \vdots \\ \bar{S}_{Mk} & \bar{S}_{Mk+1} & \cdots & \bar{S}_{MK} \end{bmatrix}. \quad (6)$$

여기서 인덱스 M 은 각 변조에 대한 총 프레임 수를 의미하며 K 는 총 변조 타입 수를 나타낸다.

2.2 데이터셋

본 논문에서는 DeepSig의 최신 버전 RadioML 2018.01A^[15]를 사용하였으며 신호를 수집하기 위한 환경조건은 중심주파수 900MHz의 ISM 대역에서 Rayleigh 페이딩 채널 조건 및 클럭오프셋 1 parts per million (ppm) 조건으로 손상된 신호를 수집하였다. 학습을 위해 적용되는 프레임 수는 하나의 변조 타입에서 4096개 프레임을 포함하고, 24개 변조 타입을 고려할 때 98,304개의 프레임 수를 가진다. 이는 SNR 각 구간에서 사용되는 프레임 수를 나타내며 고려된 SNR 범위는 0dB에서 20dB에서 2dB 간격을 따라 프레임 수를 가진다. 딥러닝 모델의 학습을 위해 데이터셋의 80%를 사용하였으며 20%는 실험을 위해 사용되었다. 마지막으로, 사용된 24개의 변조 타입은 아래와 같이 나타내었다.

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

III. 제안된 딥러닝 모델

3.1 CNN 모델

딥러닝 모델은 지도학습의 인공신경망에서 파생되었으며 그중 CNN은 다른 딥러닝 기법에 비해 강력한 예측성을 가진다. 초기에 제안된 CNN은 이미지 분류를 위해 사용되었으나, 다양한 응용 분야에 구조를 변형하여 적용되어 졌다. 본 논문에서 사용되는 CNN은 변조 타입의 분류를 위한 목적으로 사용되며 일반적인 CNN은 입력 계층에서 입력값을 입력 받고, 다음 컨볼루션 계층으로 전달되어 특징 맵을 생성하게 된다. 이때 컨볼루션 연산은 κ 번째 특징맵(z)을 만들기 위해 아래의 식과 같이 나타낼 수 있다.

$$z_\kappa = \sum_{i=1} \sum_{j=1} (F_{i,j} \times X_{i+m,j+n}) + b. \quad (7)$$

여기서 i, j, m, n 는 각각 필터의 세로, 가로 인덱스, 입력값의 공간적 세로, 가로 좌표를 나타내며 F 는 컨볼루션 필터이고, X 는 입력값, 그리고 b 는 바이어스 값이다. 컨볼루션 계층을 통한 출력은 최소 배치 사이즈를 규모로 배치 정규화 계층을 통해 특징값을 정규화할 수 있으며 이는 학습의 효율과 일반화 성능을 높여준다. 배치 정규화는 아래 식으로 나타낼 수 있다.

$$z'_\kappa = \frac{z_\kappa - \mu_B}{\sqrt{\sigma_B^2 + \rho}}. \quad (8)$$

여기서 μ_B 는 최소 배치의 평균값이며 σ_B^2 는 최소 배치의 분산값으로 $\frac{1}{\kappa} \sum_{\kappa=1} (z_\kappa - \mu_B)^2$ 를 통해 얻을 수 있으며 그리고 ρ 는 분모가 0이 되지 않도록 주어지는 매우 작은 값으로 임의로 지정된다. 배치 정규화의 출력은 비선형 활성화 함수를 통해 다음 계층으로 생성된 특징맵을 전달하며, 여기서 비선형 활성화 함수는 ReLU (Rectified Linear Units) 함수를 사용하였고 아래와 같이 나타낼 수 있다.

$$f(z'_\kappa) = \begin{cases} 0, & \text{if } z'_\kappa < 0, \\ z'_\kappa, & \text{if } z'_\kappa \geq 0, \end{cases} \quad (9)$$

마지막으로 완전 연결 계층을 통해 출력을 1차원 배열로 나열하고 Softmax 계층에 적용하여 클래스 별로 예측확률을 계산하고 이를 근거로 CNN 모델은 최종 출력을 결정한다, 여기서 Softmax는 아래와 같이

나타낼 수 있다.

$$\sigma_{softmax}(z'_\kappa) = \frac{e^{z'_\kappa}}{\sum_{i=1}^K e^{z'_i}} \quad (10)$$

여기서 분모는 입력받은 1차원 배열의 전체 요소를 더한 값이며 각 요소에 대해 나누어 확률을 계산한다. 제안하는 모델은 Stochastic Gradient Descent with Momentum (SGDM) 최적화 기법을 사용하여 손실 값을 최소화하였으며, 여기서 사용되는 가중치(w)는 아래 식을 통해 갱신할 수 있다.

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

$$\text{where, } Q(w_t) = \frac{1}{L} \sum_{t=1}^L (\hat{y}_t - y_t)^2. \quad (11)$$

$$w_{t+1} := w_t + v_{t+1}. \quad (12)$$

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

3.2 제안된 CNN 모델

제안된 모델은 VGG와 같이 계층을 적층하는 구조에서 기울기가 소실되는 문제를 해결하기 위해 ResNet의 스킵커넥션 방식을 추가하여 정확도를 향상시킬 수 있도록 하였고, 또한 계산 복잡도를 줄이기 위해 포인트와이즈 컨볼루션 방식을 적용하여 학습 파라미터의 수를 낮추도록 하였다. 제안된 CNN 구조는 그림2에 나타내었으며 총 4개의 블록을 통해 주요 특징맵을 추출하고 나머지 계층에서 분류 및 예측을 위해 구성된다.

그림 2a는 전체 CNN 구조에 대해 나타내었으며 입력 계층으로부터 입력값을 받은 후 처음 2개의 블록을 통해 특징맵을 추출하고 2×1 의 평균풀링 계층을 통해 4×1024 특징맵 크기를 2×1024 크기로 압축시킨다, 여기서 압축된 특징맵은 역순으로 확장된 프레임에 의해 기존의 프레임과 다른 특징맵을 형성하게 되고 이는 각 변조 타입에 대한 특징정보를 압축되는 과정에서 중요 특징을 좀 더 유지하게 하는 효과를 가진다. 기존의 프레임 압축된 특징맵은 2개의 블록을 통과한 후 글로벌 평균풀링 계층을 통과하여 특징맵 크기를 1×1 로 줄이고 완전연결 계층과 Softmax

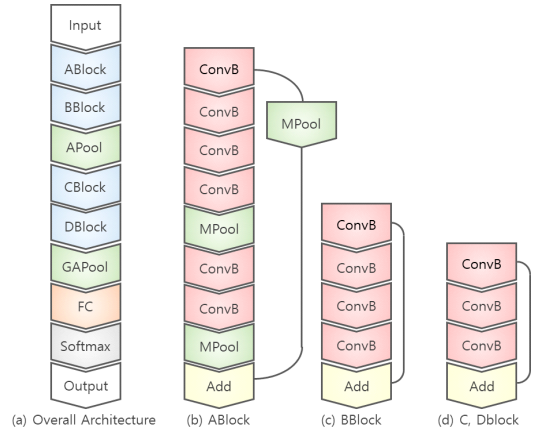


그림 2. 제안된 CNN 구조
Fig 2. The proposed CNN architecture

계층을 통해 최종 변조타입을 예측하는 순서로 진행된다. 그림 2b는 처음 ABlock에 대해 나타내었으며 총 6개의 컨볼루션 블록과 3개의 최대풀링 계층을 사용한다. 컨볼루션 블록(ConvB)는 컨볼루션 계층, 배치정규화 계층 그리고 활성화 계층으로 구성되며 활성화 계층에서 ReLU 함수를 네트워크 전체 구조에서 일괄적으로 적용하였다. 컨볼루션 계층 옵션의 경우 모든 컨볼루션 연산 시 스트라이드는 1×1 로 동일하게 설정하였으며 컨볼루션 연산을 통해 출력 크기가 축소되지 않도록 공통 패딩을 설정하였다. 컨볼루션 블록을 따라 연결된 2개의 최대풀링 계층은 1×2 필터와 1×2 스트라이드를 사용하여 중요하지 않는 특징들을 제거하고 면적 크기를 줄여 학습속도를 높이도록 하였으며, 특징맵 크기를 1024에서 512 그리고 256의 길이로 축소된다. 스킵 커넥션에 연결된 최대풀링 계층은 1×4 필터와 1×4 스트라이드를 사용하여 동일 면적 크기로 조정하여 더해질 수 있도록 하였다. 그림 2b는 컨볼루션 블록을 쌓아 더 깊은 특징을 추출할 수 있도록 하였으며 처음과 마지막 컨볼루션 블록을 포인트와이즈 컨볼루션 연산으로 적용하여 학습 파라미터 수를 낮추었으며 중간에 위치한 컨볼루션 블록은 1×3 , 3×1 비대칭 필터를 사용하여 동일한 효과를 가지는 3×3 필터를 적용한 것보다 계산 복잡도를 낮추도록 하였다. 그림 2d는 CBlock과 DBlock에 적용된 구조로 BBlock에 적용된 구조와 유사하게 처음과 마지막 컨볼루션 블록은 포인트와이즈 컨볼루션 연산을 하며 중간에 위치한 컨볼루션 블록은 1×3 필터를 통해 컨볼루션 연산을 하도록 하였다. 이는 4×256 프레임에서 2×256 으로 압축된 상태로 3×1 필터를 통한 각 행의 특징 추출에 대한 효과가

표 1. 제안된 CNN 모델 구조 설명
Table 1. The description of proposed CNN model.

Type	Filter Size	Output Size	Parameters
Input	-	4 × 1024	-
ABlock	ConvB	1 × 3	4 × 1024 × 16
	ConvB	3 × 1	4 × 1024 × 16
	ConvB	1 × 5	4 × 1024 × 16
	ConvB	5 × 1	4 × 1024 × 16
	MPool	1 × 2	4 × 1024 × 16
	ConvB	1 × 3	4 × 512 × 16
	ConvB	3 × 1	4 × 512 × 16
	MPool	1 × 2	4 × 256 × 16
BBlock	ConvB	1 × 1	4 × 256 × 32
	ConvB	1 × 3	4 × 256 × 16
	ConvB	3 × 1	4 × 256 × 16
	ConvB	1 × 1	4 × 256 × 32
APool	2 × 1	2 × 256 × 32	-
CBlock	ConvB	1 × 1	2 × 256 × 64
	ConvB	1 × 3	2 × 256 × 24
	ConvB	1 × 1	2 × 256 × 64
DBlock	ConvB	1 × 1	2 × 256 × 128
	ConvB	1 × 3	2 × 256 × 32
	ConvB	1 × 1	2 × 256 × 128
GAPool	-	1 × 1 × 128	-
FC	-	1 × 1 × 24	3,096
Softmax	-	1 × 1 × 24	-
Output	-	-	-
Total	-	-	46,000

표 2. CNN 모델 모의실험 설정
Table 2. The configuration of CNN simulation.

Type	Value
MaxEpochs	45
MiniBatchSize	64
InitialLearnRate	0.1
LearnRateDropPeriod	20
LearnRateDropFactor	0.1
Optimizer	SGDM

모델과 성능 비교를 위하여 최신 CNN 모델인 LCNN^[16], MCNet^[11]를 포함한 ResNet^[15] 등과 SNR에 따른 비교를 통하여 성능을 나타내었으며 제안한 모델이 기존의 모델보다 검출 확률 성능이 우수한 것을 보였다.

그림 3은 0 - 20 dB SNR 구간에서 각 모델의 검출확률 성능을 나타내었으며 낮은 SNR 구간에서 높은 SNR로 증가할수록 각 변조 타입에 대한 특징이 명확해지므로 각 기법의 검출 확률이 증가하는 것을 볼 수 있다. 제안된 모델의 경우 다른 모델보다 SNR 전 구간에서 다른 기법보다 높은 검출 확률 성능을 가지며 대표적으로 SNR 0 dB와 10 dB에서 각 기법에 대한 검출 확률을 다음과 같이 비교분석 하였다. 낮은 SNR 대역인 0 dB에서 ResNet, MCNet, LCNN 그리고 제안된 모델은 45.92%, 53.51%, 56.64% 그리고 57.51% 각각 검출 확률을 가진다. 그리고 일반적인 FB 방식인 SVM과 XGboost는 28% 그리고 38.71%를 가짐으로 제안된 모델이 최소 1.5% 높은 성능을 보였다. 또한 높은 SNR 대역인 10 dB에서는 ResNet, MCNet, LCNN 그리고 제안된 모델이 각각 73.66%,

제한적이기 때문이다. 제안된 CNN 구조에 적용된 필터 크기와 출력 크기 그리고 학습 파라미터 수에 대한 부분을 표 1에 요약하였다.

IV. 시뮬레이션 결과

본 논문에서 제안된 CNN 모델의 모의실험을 위해 데이터셋의 80%는 학습 데이터로 20%는 시험 데이터로 적용 후 성능을 평가하였으며 모의실험을 위한 환경설정은 표 2를 통해 요약하였다. 네트워크 해석 프로그램은 Matlab 2020b를 사용하였으며 하드웨어 장비는 CPU i5-9400F, RAM 32GByte, GPU NVIDIA RTX 2080 SUPER으로 구성하였다. 제안된




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

86.06%, 91.48% 그리고 93.85%의 검출 확률을 가지며 SVM과 XGBoost는 각각 49.02%, 61.13% 검출 확률을 가진다. 따라서 SNR 10 dB에서 제안된 모델이 비교된 성능에 따라 최소 2.5% 높은 성능을 가지는 것을 볼 수 있다. CNN 모델 중 성능이 가장 낮은 ResNet은 6개의 컨볼루션 블록과 2개의 완전연결층을 적용하여 네트워크의 깊이가 가장 깊은 구조를 가지고 있다. 따라서, 학습 시 오버피팅률이 증가하여 일반화 정도가 낮아 질 수 있다. 또 지정된 특징을 사용한 머신러닝의 SVM과 향상된 결정트리 방식의 XGboost는 성능면에서 한계를 가짐을 알 수 있다.

그림 4는 제안된 모델을 통한 APSK와 M-PSK에 대한 성능을 나타내었으며 SNR 0 dB에 높은 SNR로 증가할 때 128 APSK 타입을 상대적으로 예측하지 못하는 것을 볼 수 있으며, 이는 노이즈와 채널 상태에 따른 신호의 손상으로 검출에 대한 어려움이 있기 때문이다. 또한 64 APSK 타입에서 128 APSK로 고차 변조 타입으로 변화 될 때 동일한 조건에서 검출하기 더 어려운 것을 보여준다. 하지만, SNR 10 dB 이상에서 각 타입에 대한 예측 정확도가 높은 것을 볼 수 있다. QPSK 타입의 경우 에러 플로어가 나타나는 것을 볼 수 있는데 이는 256QAM 타입과 유사성이 있어 혼동하고 있기 때문이며 이에 대한 비교 결과는 그림 7을 통해 나타내었다.

그림 5은 QAM, ASK, GMSK 그리고 OOK 변조 타입에 대한 성능을 나타내었다. 성능 결과에 따라 64/256 QAM은 높은 SNR 영역에서도 검출 확률이 상대적으로 크게 낮은 것을 볼 수 있다. 일반적으로 다른 기법의 경우 높은 SNR 영역에서 검출 확률이




그림 4. 제안된 모델의 APSK/PSK 변조 방식 성능 비교
Fig. 4. Performance comparison of proposed model for PSK




그림 5. 제안된 모델의 QAM/ASK/GMSK/OOK 변조 방식 성능비교
Fig. 5. Performance comparison of proposed model for QAM/ASK/GMSK/OOK

높게 나오는 것을 고려 하였을 때 2가지 기법의 경우 CNN 모델이 높은 SNR 영역에서 주요한 특징을 추출하지 못하는 것을 볼 수 있으며, 따라서 다른 변조 타입과 쉽게 혼동하고 있음을 볼 수 있다, 여기서 64QAM은 AM-SSB-WC로 256QAM은 QPSK로 혼동예측하는 것을 그림 7을 통해 알 수 있다.

그림 6은 FM과 AM 타입에 대한 검출성능을 나타내었으며 AM 타입은 아날로그 변조 타입을 나타낸다. 여기서 가장 검출 확률이 낮은 기법은 AM-DSB-SC로 높은 SNR 영역에도 90% 이상의 검출 확률을 가지지 못한다. 이는 다른 디지털 변조 타입과 쉽게 혼동하여 검출하기 때문이다. 반면에 나머지 변조 타입은 높은 SNR 영역에서 90% 이상의 검출 성능을 보이고 있다.

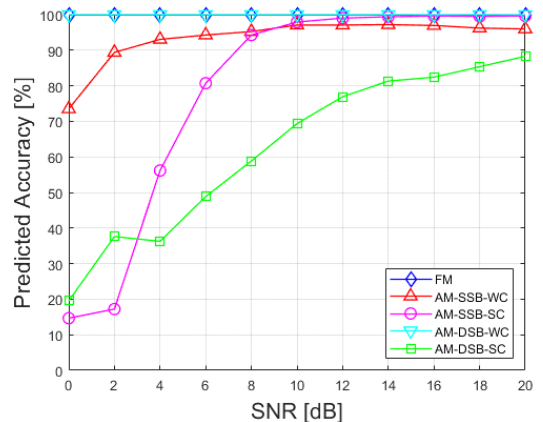


그림 6. 제안된 모델의 FM/AM 변조 방식 성능비교
Fig. 6. Performance comparison of proposed model for FM/AM

그림 7에서 SNR 10 dB에서 24가지 변조 타입의 불일치 정도에 대해 직관적으로 분석을 위하여 시각화하여 나타내었으며 10 dB에서 3가지 타입이 불일치가 높게 발생한 것을 볼 수 있다. 따라서 낮은 SNR과 높은 SNR 간의 성능 비교를 통하여 낮은 SNR 영역으로 진행할 때 불일치 정도가 높은 변조 타입에 대해 파악할 수 있으며 이를 고려하여 응용 분야에 따라서 네트워크를 재설계 및 적용 할 수 있다. 10 dB에서 불일치가 높은 64 QAM의 경우 주로 AM-SSB-WC 변조 방식으로 잘못 예측하였으며, 256 QAM의 경우에는 주로 QPSK 변조 방식을 잘못 예측하였다. 그리고 AM-DSB-SC는 128APSK와 128QAM을 주로 잘못되게 검출한 것을 볼 수 있다.

그림 8은 각 CNN 모델에 대한 계산 복잡도로 학습 파라미터와 검출 시간에 대해 구분하여 나타내었다. 먼저 제안된 모델에서 사용된 파라미터 수는 46k로 다른 모델 ResNet (236k), MCNet (142k) 보다 크게 낮은 파라미터 수를 사용하는 것을 볼 수 있으며, LCNN (46k)의 경우 동일한 파라미터 수를 사용하였

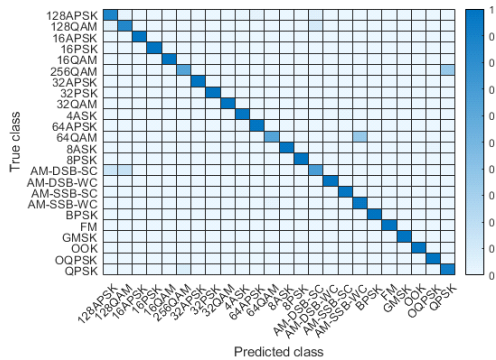


그림 7. SNR 10 dB, 93.85% 검출 확률에 대한 분류결과표
Fig. 7. Confusion matrix for accuracy 93.85% at SNR 10 dB

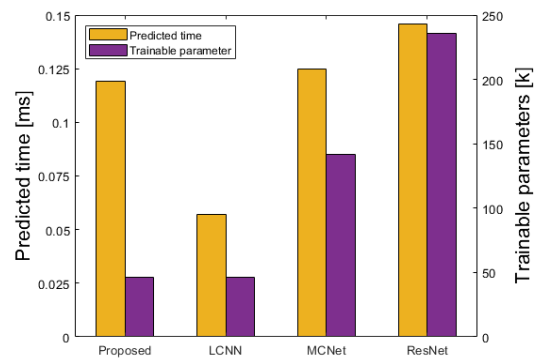


그림 8. 각 모델의 복잡도 비교
Fig. 8. Computation complexity of each model.

다. 1 프레임 당 예측시간의 경우 ResNet과 MCNet보다 각각 6.2%, 4.8% 예측시간이 짧았지만, LCNN과 비교 시 학습 파라미터 수가 동일하지만 약 2배 더 높은 검출 시간이 걸린 것을 알 수 있다. 이는 입력크기를 크게하였고 컨볼루션 계층을 통한 네트워크의 깊이를 증가시켜 이에 대한 검출 시간이 증가한 것을 알 수 있다. 따라서, 검출 확률 성능 부분에서는 제안된 모델의 성능이 LCNN 보다 높으며, 계산 복잡도 성능 부분에서는 낮은 것을 고려할 때 입력 크기를 확대함을 통해 트레이드오프가 발생함을 알 수 있다.

V. 결론 및 향후연구

본 논문에서는 인지 무선 기술에서 자동 변조 분류를 위한 입력 크기를 확대한 CNN 모델을 제안하였다. 수신부에서 가지고 있는 프레임을 복사 및 적용하는 것으로 검출 확률이 증가한 것을 볼 수 있으며 이는 발신부에서 제공된 제한적인 프레임으로도 검출 확률을 높일 수 있음을 확인하였다. 모의실험을 통해 제안된 모델의 검출 확률 성능이 기존의 모델보다 SNR 전 구간에서 우수한 것을 확인하였으며, 특히 SNR 10 dB에서 최신 모델 LCNN보다 2.5% 이상 높은 검출 확률을 보였다. 반면에 검출 시간의 경우 LCNN 보다 약 2배 증가한 것을 통해 제안된 방식이 트레이드오프가 발생함을 볼 수 있다. 향후 연구로는 고차원 변조 방식에 대한 심층 특징 추출에 대한 기법을 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] D.-S. Kim, Y. S. Lee, W. H. Kwon, and H. S. Park, "Maximum allowable delay bounds of networked control systems," *Control Eng. Practice*, vol. 11, no. 11, pp. 1301-1313, Nov. 2003.
- [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] T. Huynh-The, C. Hua, J. Kim, S. Kim, and D. Kim, "Exploiting a low-cost CNN with skip connection for robust automatic modulation classification," in *Proc. IEEE WCNC*, pp. 1-6, Seoul, Korea, May 2020.
- [5] T. Yucek and H. Arslan, "A survey of spectrum sensing algorithms for cognitive radio applications," *IEEE Commun. Surv. & Tuts.*, vol. 11, no. 1, pp. 116-130, First Quarter 2009.
- [6] S. Haykin, "Cognitive radio: Brain-empowered wireless communications," *IEEE J. Sel. Areas in Commun.*, vol. 23, no. 2, pp. 201-220, Feb. 2005.
- [7] H. Zhang, Y. Wang, L. Xu, T. Aaron Gulliver, and C. Cao, "Automatic modulation classification using a deep multi-stream neural network," *IEEE Access*, vol. 8, pp. 43888-43897, Feb. 2020.
- [8] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436-444, May 2015.
- [9] A. Krizhevsky, I. Sutskever, and G. Hinton, "ImageNet classification with deep convolutional neural networks," in *Proc. NIPS*, vol. 1, pp. 1097-1105. Dec. 2012.
- [10] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proc. IEEE Conf. CVPR*, pp. 770-778, Las Vegas, USA, Dec. 2016.
- [11] T. Huynh-The, C. Hua, Q. Pham, and D. -S. Kim, "MCNet: An efficient CNN architecture for robust automatic modulation classification," *IEEE Commun. Lett.*, vol. 4, no. 2, pp. 811-815, Apr. 2020.
- [12] S. Hong, Y. Zhang, Y. Wang, H. Gu, G. Gui, and H. Sari, "Deep learning-based signal modulation identification in OFDM systems," *IEEE Access*, vol. 7, pp. 114631-114638, Aug. 2019.
- [13] H. Gu, Y. Wang, S. Hong, and G. Gui, "Blind channel identification aided generalized automatic modulation recognition based on deep learning," *IEEE Access*, vol. 7, pp. 110722-110729, Aug. 2019.
- [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] 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.
- [16] 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.

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, 무선 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

김재우 (Jae-Woo Kim)



2004년 2월 : 금오공과대학교 컴
퓨터공학과 졸업

2006년 2월 : 금오공과대학교 컴
퓨터공학과 석사 졸업

2013년 8월 : 금오공과대학교 컴
퓨터공학과 박사 졸업

2014년~2018년 : (주)에이알텍 광통신 연구소 차장

2018년~현재 : ICT융합특성화연구센터 연구교수.

<관심분야> 산업용 IoT, 임베디드 시스템, 지능형 엣지
컴퓨팅

김동성 (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
(과기정통부 Grand ICT 및 연구재단 중점연구소)

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]