

딥러닝 기반 자동 변조 분류 위한 CNN 모델 성능 분석

김승환, 권기협, 김동성

금오공과대학교 ICT융합특성화연구센터

ksh001@kumoh.ac.kr, navkwon@kumoh.ac.kr, dskim@kumoh.ac.kr

Performance Analysis of Convolutional Neural Network Model for Deep Learning-Based Automatic Modulation Classification

Seung-Hwan Kim, Ki-Hyeop Kwon, Dong-Seong Kim

KIT ICT Convergence Research Center.

요약

본 논문은 무선 인지 네트워크에서 딥러닝 기반의 자동 변조를 위해 사용되는 CNN 모델에 대해 필터 크기에 따라 변화되는 예측성능에 대해서 분석하였다. 성능분석을 위해 사용된 데이터셋은 Deepsig의 RADIOML 2018.01a 그리고 RML2016.10b를 사용하였다. 기존의 모델에서 사용한 1×3 의 필터를 1×5 , 1×8 그리고 1×11 크기로 대체하여 나타나는 성능에 대해 나타내었다. 성능 분석에 따라서 1×8 필터가 최적의 필터 크기인 것을 보였다.

1. 서론

무선통신 기술의 발전을 통해 IoT 모바일 기기에 대한 서비스 증가로 주파수 자원에 대한 고갈 현상이 심화되면서 산업 분야[1], 군사 분야 등 다양한 응용 분야에 대한 서비스를 제공에 한계점을 가지게 된다. 이러한 문제를 해결하고자 인지통신기술이 보급되었고 이는 제한된 주파수 자원을 효율적으로 사용할 수 있도록 하게 한다. 인지통신기술은 면허 주파수 대역을 허가되지 않은 사용자(부 사용자)가 유휴 채널을 사용 가능하도록 하는 기술이며 부 사용자는 인가된 사용자(주 사용자)의 통신을 방해하지 않는 조건을 가지고 있다. 따라서 주 사용자의 통신에 간섭하지 않도록 하기 위해 인지통신을 가능하게 하고 부 사용자가 네트워크 채널을 사용하도록 하는 다양한 기법들이 구성되어 있으며, 그 중 자동변조분류 기법[2]은 부 사용자가 채널을 사용하기 위한 필수적 기법이다. 자동변조분류 기법은 수신된 신호를 사전지식 없이 변조 종류를 식별해내는 기법으로 기존의 2가지 방식을 통해 연구 되었다. 첫째는 최대 우도추정 기반의 분류 방식이며, 두 번째는 특징 기반의 패턴인식 방식이다. 최대 우도추정 방식을 적용 시 최적의 성능을 보장하지만 구현하기 위한 매우 높은 복잡도가 발생함으로 차선의 성능을 가지는 패턴인식 방식이 일반적으로 적용된다. 패턴인식 방식의 분류 진행과정은 입력 데이터 전처리, 특징추출, 마지막으로 분류결정으로 3단계로 진행되지만 딥러닝 기반 패턴인식 방식[3]은 입력 데이터 전처리와 특징추출/분류결정으로 2단계로 진행된다. 본 논문에서는 Deepsig Dataset: RML 2018.01a 데이터셋과 RML 2016.10b 데이터셋을 활용하여 각 필터 크기에 대한 성능을 분석하였다.

II. 시스템 모델

송신부의 전송된 신호는 클럭 오프셋과 채널 페이딩에 의해 손상되어 수신부를 전송이 되며 k 번째 수신된 신호는 식 1과 같이 나타낼 수 있다.

$$y_k = \alpha e^{j(2\pi \Delta f t + \Delta \phi)} x_k + n. \quad (1)$$




그림 1 Example of system model.

여기서 α 는 다중 경로의 진폭이며, Δf 와 $\Delta \phi$ 는 캐리어 주파수와 위상의 오프셋, x_k 는 변조신호 그리고 n 는 백색가우시안잡음을 나타낸다.

신호의 자동 변조 분류를 위해 사용된 데이터셋 RML 2018.01a는 1024 샘플을 1프레임으로 구성하여 총 884,736 프레임을 사용하였으며 각 변조 타입 당 4096 프레임이 사용하였다. RML 2016.10b의 경우 128 샘플을 1프레임으로 구성하여 총 540,000 프레임이 사용되었으며 각 변조 타입 당 6,000 프레임이 사용하였다. RML 2018.01a의 경우 측정된 SNR 구간은 0 dB에서 16 dB이며 2 dB의 간격으로 예측성능을 나타내었고 RML 2016.10b의 경우 SNR 구간은 -10 dB에서 6 dB이며 2 dB의 간격으로 예측성능을 나타내었다. 수신된 신호 프레임으로 재구성하여 식 2를 통해 RMS 방식으로 정규화하였으며, 정규화된 신호는 In-phase, Quadrature-phase (IQ) 요소로 분리 후 딥러닝 네트워크에 학습 하였다.

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

III. CNN 모델 성능분석

CNN 모델을 통한 특징을 추출하기 위해 컨볼루션 레이어를 통해 특징맵을 생성하고 액티베이션 레이어를 통해 비선형적으로 출력된 특징맵을 적층한다. 컨볼루션 레이어와 액티베이션 레이어 사이 배치 정규화 레이어

어를 사용하여 일반화 성능을 높여 학습 속도와 정확도를 높이기 할 수 있다. 특징맵 생성 시 컨볼루션, 배치 정규화 그리고 액티베이션 레이어를 하나의 컨볼루션 블록의 기능으로 두었고 각각에 대한 식은 식 2-4를 통해 나타내었다.

$$z_k = \sum_i w_i v_i + b, \quad (2)$$

여기서 v_i 는 입력값, w_i 는 컨볼루션 계수이고 그리고 b 는 바이어스 값이다. 배치 정규화에 대한 부분은 식 3을 통해 나타내었다.

$$\hat{z}_k = \frac{z_k - \mu_B}{\sqrt{\sigma_B^2 + \rho}}, \quad (3)$$

여기서 μ_B 는 최소 배치의 평균값이며 σ_B^2 는 최소 배치의 분산값 그리고 ρ 는 분모가 0이 되지 않도록 주어지는 작은 값이다. 마지막으로 액티베이션 레이어는 식 4를 통해 나타내었다.

$$f(\hat{z}_k) = \begin{cases} 0, & \text{if } \hat{z}_k < 0, \\ \hat{z}_k, & \text{otherwise,} \end{cases} \quad (4)$$

제안하는 CNN은 SGDM (Stochastic Gradient Descent with Momentum) 최적화 기법을 사용하였다. 제안된 CNN 구조는 그림 2, 3을 통해 나타내었으며, 그림 3에서 ConvB는 컨볼루션 블록, MPool은 MaxPooling 레이어, APool은 AveragePooling 레이어, GAPool은 Groval APool 레이어, DO는 DropOut 레이어, FC는 Fully-Connected 레이어, SM은 Softmax 레이어 그리고 CO는 Classification Output을 각각 의미한다. 그림 2에서 ConvB의 (1×8) , (3×1) 그리고 (1×1) 은 컨볼루션 레이어 필터 크기를 나타내며 여기서 (1×8) 필터 크기 사용하는 각 레이어를 (1×3) , (1×5) 그리고 (1×11) 로 각각 크기를 적용하여 성능을 비교 분석하였다. 그림 2에서 제안된 CNN 모델은 총 3개의 블록과 출력으로 구성되며, 18개 컨볼루션을 통해 특징맵을 추출하였다. 1024 또는 128 입력 길이는 ABlock에서 사용된 MPool을 통해 축소하였고, CBlock의 APool을 통해 2-Dimension 특징맵을 1-D로 축소하도록 하여 계산복잡도를 낮추었다. 출력단에서는 FC 레이어에 전달된 입력 크기는 글로벌 평균풀링을 적용하여 1×1 로 조정하여 학습 파라미터 수를 낮추었다.




그림 2 신호 기반 CNN 아키텍처.




그림 3 CNN 모델 구조 (a)ABlock (b)BBlock (c)CBlock (d)Output.

IV. 시뮬레이션 결과

본 논문에서 제안된 모델의 성능 분석을 그림 3, 4를 통해 각 데이터셋에 대한 비교결과를 나타내었다. 시뮬레이션을 위한 환경 설정은 최소 배치 크기 64, 최대 Epoch 40, 초기 학습비율 0.1 그리고 Epoch 35마다 0.1 학습 비율을 낮추도록 하였다. 결과를 통해서 두 가지 데이터셋 모두

(1×8) 의 필터를 사용 하였을 때, 최적의 성능을 가지는 것을 볼 수 있다. 각 필터의 성능 차이는 낮은 SNR에서 높은 SNR로 증가할 때, 따라서 최저 분류 정확도에서 최고 분류 정확도로 천이 될 때 각 필터에 대한 분류 성능이 뚜렷하게 나타나는 것을 볼 수 있다. 따라서 본 시험을 통해 필터 크기가 증가 할수록 최저 그리고 최대 성능을 높이는 것이 아니라 천이되는 과정에서 분류 성능을 높이는 것을 볼 수 있다.




그림 4 Performance comparison with RML 2016.10b




그림 5 Performance comparison with RML 2018.10a

V. 결론

본 논문에서는 자동 변조 분류를 위해 CNN 모델을 제안하고 컨볼루션 필터 크기에 대한 성능을 분석하였다. 제안된 모델의 성능분석을 위해 RML 2018.01a, RML 2016.10b 데이터셋을 사용하였으며 (1×8) 의 필터 크기를 사용할 때 최적의 성능을 보이는 것을 나타내었다.

ACKNOWLEDGMENT

이 논문은 정보통신기획평가원의 Grand ICT연구센터지원사업 (IITP-2020-2020-0-01612)과 한국연구재단의 대학중점연구소 지원사업으로 수행된 연구임(2018R1A6A1A03024003).

참고 문헌

- [1] S.-H. Kim, J.-W. Kim and D.-S. Kim, "Energy Consumption Analysis of Beamforming and Cooperative Schemes for Aircraft Wireless Sensor Networks," *Appl. Sci.*, vol. 10, no. 12, pp. 4374-4391, Jun. 2020.
- [2] 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, June 2021.
- [3] 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.