

사전훈련된 네트워크를 활용한 이미지 기반 자동 변조 분류 모델 설계

김승환, 김동성*

금오공과대학교 ICT융합특성화연구센터

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

Design of image based-Automatic Modulation Classification Model Through Transfer Learning

Seung-Hwan Kim, Dong-Seong Kim*

Kit ICT Convergence Research Center.

요약

본 논문은 자동 변조 분류를 위해 사전훈련된 네트워크를 통한 데이터 특징을 추출하고 추출된 특징을 이미지로 변환하여 이미지 기반의 딥러닝 모델을 적용하였다. 사용된 데이터셋은 RADIOML 2018.01A 데이터셋을 사용하였으며 이미지를 통한 모델의 예측 성능과 특징을 추출하지 않고 복소신호를 입력으로 하였을 때 이에 대한 성능분석을 나타내었다. 두가지 방식을 통한 예측 성능을 비교하였을 때 이미지 기반 예측 성능이 약 2% 더 높은 것을 나타내었다.

I. 서론

5G 무선통신 기술은 낮은 비용과 낮은 간섭 등의 장점으로 차세대 통신 기술로 많은 주목을 받고 있다. 5G 통신기술 중 하나인 가시광 통신이 있으며 가시광 통신의 처리량을 향상시키기 위해 자동 변조 방식을 적용할 수 있으며 이는 낮은 주파수와 높은 주파수 대역에서 스펙트럼 효율을 향상 시킬 수 있다[1]. 자동 변조 방식은 기존의 2가지 방법을 사용하고 있다. 첫 번째로 가시도 기반의 방식이 있으며 두 번째로 특징 기반의 방식을 통해 변조 종류를 분류하는 모델을 설계하였다. 가시도 기반 방식의 경우 변조 종류 분류에 대한 성능은 뛰어나지만 복잡도가 높은 단점이 있다. 특징 기반의 방식은 머신러닝 분류기에 고차 쿼터런트 등의 특징 추출 데이터를 적용한 방식을 사용하였다. 특징 기반 방식은 가시도 기반 방식보다 성능적으로 우수하지 못하지만 복잡도가 낮아 구현 가능한 장점을 가진다. 기존의 Support Vector Machine (SVM), Decision Tree (DT), k-Nearest Neighbor (kNN) 등 머신러닝 방식은 우수한 성능을 도출하지만 성능 향상에 대한 한계점을 가진다. 최근 머신러닝 기술을 대체하기 위해 딥러닝 기술이 제안되었고 다양한 응용분야에 적용되고 있다. 딥러닝 기술 중 Convolutional Neural Network (CNN)은 학습 데이터셋을 통한 자동으로 특징을 추출하며 각 클래스 별로 분류처리를 한다. 본 논문에서는 사전훈련된 네트워크를 통해 데이터셋에 대한 특징을 추출하고 이미지로 변환하여 제안된 CNN을 통해 예측 정확도 성능을 분석하였다.

II. 시스템 모델

본 논문에서 사용된 데이터셋은 DEEPSIG DATASET: RADIOML 2018.01A로 기존에 학습된 CNN을 통해 데이터셋에 대한 특징을 추출하고 추출된 데이터셋을 수치에 따른 이미지 색으로 변환하여 제안된 CNN에 학습하여 신호를 분류하도록 하였다. 데이터셋 구성은 총 프레임 1,572,864개를 가지며 각 프레임은 1024 샘플 신호로 구성된다. 총 변조 종류는 24로 24개 클래스를 가지며 각 클래스 별로 98,304의 프레임이 사용




그림 1 System Model

되었다. SNR 구간은 -10 dB에서 20 dB이며 2 dB의 간격으로 각 프레임이 수집되었다. 수집된 데이터는 레일리 페이딩과 클럭오프셋을 통해 손상된 신호가 수집되었으며 해당 중심주파수는 900MHz이다. 전송된 k 번째 신호는 식 1과 같이 나타낼 수 있다.

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

여기서 α 는 다중 경로의 진폭이며, Δf 와 $\Delta \phi$ 는 캐리어 주파수와 위상의 오프셋, x_k 는 변조신호 그리고 n 는 AWGN을 나타낸다. 수신된 신호는 1024 샘플로 구성되어 1개의 프레임을 나타내며 식2의 RMS 방식을 통해 정규화를 하였다. 정규화된 데이터는 In-phase, Quadrature-phase 컴포넌트로 변환된 후 기존에 학습된 CNN을 통해 그림 1과 같이 특징을 추출하였고 추출된 특징은 1 프레임 당 24개의 샘플을 가지며 각 샘플의 스케일에 따라 색이 지정되도록 하였다.

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




그림 2 Example of extraction through pre-trained CNN

마지막으로 이미지로 변환하기 위해 24개의 샘플을 고려하여 하나의 샘플 당 하나의 픽셀로 고려하였으며, 따라서 24×1 크기로 이미지를 변환하였고 색상에 대한 채널 수를 고려하여 제안된 네트워크의 입력 크기는 $24 \times 1 \times 3$ 으로 지정하였다.

III. 제안된 CNN 모델

CNN에서 컨볼루션 레이어를 통한 연산은 식(3)과 같이 표현할 수 있으며 w 와 스칼라 바이어스 b 는 학습을 통해 갱신되어 진다. 컨볼루션 연산 완료 후 비선형 활성화함수 레이어를 통해 특징맵이 생성되게 된다. 여기서 활성화함수를 사용하는 이유는 심층 학습을 할 수 있도록 하기 위해서이다.

$$\text{conv}_{x,y} = \sum_i w_i v_i + b. \quad (2)$$

여기서 w_i 합성곱 커널 가중치를 의미하고, v_i 는 입력값을 의미한다. CNN을 네트워크에 사용되는 옵티마이저는 SGDM (Stochastic Gradient Descent with Momentum)를 사용하여 손실 값을 최소화하도록 하였다. 여기서 사용되는 가중치(w)는 아래와 같이 나타낼 수 있다.

$$w_{t+1} := \alpha w_t - \eta \nabla Q(w_t), \quad (3)$$

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

$$w_{t+1} := w_t + v_{t+1}, \quad (4)$$

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 참값을 나타낸다.

이미지 기반 CNN 모델은 [2]의 모델을 변환하여 설계하였으며, 총 16개의 컨볼루션 레이어를 포함하고 있으며 3개의 풀링 레이어를 사용한다. 각 컨볼루션 레이어는 배치정규화 레이어와 활성화 레이어를 통과하여 특징맵을 출력하며, 네트워크에서 사용되는 학습 가능 파라미터 수는 81,688이다. 복소신호 기반 CNN 모델은 기존 사전 훈련된 모델로 사용된 [2] 모델을 사용하여 데이터셋을 학습하였고 성능을 나타내었다. 여기서 사용된 컨볼루션 레이어는 14개이며 학습 가능 파라미터 수는 40860이다.

IV. 시뮬레이션 결과

본 논문에서 제안된 모델은 Matlab 2021a 프로그램을 통해 제안된 모델을 시뮬레이션 하였으며 결과는 그림 3, 4와 같이 비교결과를 높은 SNR에서 성능 그래프와 혼돈 행렬로 나타내었다. 시뮬레이션을 위한 환경 설




그림 3 Performance of accuracy and loss at 10 dB




그림 4 Image-based model confusion matrix at 10 dB

정은 최소 배치 크기 64, 최대 Epoch 45, 초기 학습비율 0.1 그리고 Epoch 20마다 0.1 학습 비율을 낮추도록 하였다. 이미지 기반 모델에서 시험 데이터셋에 대한 정확도는 SNR 10 dB에서 94.46%를 보였고 신호 기반 모델의 정확도는 92.4%이다. 따라서 두 모델의 정확도는 2% 이상 이미지 기반 모델의 성능이 우수한 것을 나타내었다.

V. 결론

본 논문에서는 자동 변조 분류를 위해 RADIOML 2018.01A 데이터셋을 사용하여 이미지 기반 CNN과 신호 기반 CNN의 비교를 통해 변조 종류를 식별에 대한 정확도를 나타내었으며 이미지 기반 모델이 신호 기반 모델보다 SNR 10 dB에서 2% 우수한 성능을 가지는 것을 나타내었다.

ACKNOWLEDGMENT

이 논문은 정부(교육부, 과기부)의 재원으로 수행된 연구임 (2018R1A6A1A03024003, IITP-2020-2020-0-01612).

참 고 문 헌

- [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, 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.