

인지 통신에서 자동 변조 분류를 위한 CNN 모델 설계

김승환, 김동성*

금오공과대학교 ICT융합특성화연구센터

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

Design of Convolutional Neural Networks
for Automatic Modulation Classification of Cognitive Radio

Seung-Hwan Kim, Dong-Seong Kim*

KIT ICT Convergence Research Center.

요약

본 논문은 인지 통신망에서 효과적인 자동 변조 분류를 위해 CNN 기술을 사용하여 변조 종류를 식별하는 모델을 제안하였다. 제안된 모델은 DEEPSIG DATASET: RADIOML 2018.01A 데이터셋을 사용하였으며 데이터셋은 24가지 종류의 변조 신호를 포함하고 있으며 수신된 신호는 클럭 오프셋, 채널 페이딩으로 인해 손상된 신호로 제안된 모델을 통해 분류 성능을 나타내었다. 제안된 모델은 최근 제안된 MCNet과 성능비교를 나타내었다.

I. 서론

무선통신 기술의 발달과 모바일 서비스의 증가로 제한적인 주파수 대역을 가지고 여러 가지 응용 분야에 대한 안정적인 서비스를 제공에 어려움을 가진다. 이러한 문제를 해결하고 주파수 대역의 사용효율을 높이기 위해 인지통신기술이 제안되었다[1]. 인지통신기술은 주 사용자의 채널사용에 간섭을 주지 않는 범위 내에서 2차 사용자가 채널을 사용하는 개념으로 이를 위해 채널 감지 및 채널 핸드오프 등의 기법에 연구가 진행되고 있다. 여기서 사용되는 채널은 다양한 사용자가 사용함으로 수신기에서 변조 방식에 대한 인지가 필요하다. 따라서, 무선 인지통신기술이 적용된 수신기는 변조기법을 자동적으로 선택하는 자동 변조 분류 기능을 포해야 한다. 자동 변조 분류의 개념은 전송되는 신호에 대한 사전지식 없이 자동적으로 신호의 변조 종류를 식별해내는 기능이다. 일반적으로 자동 변조 분류기능은 2가지 기법으로 구분할 수 있으며, 첫 번째로 최대 우도추정 기반의 분류 방식이 있고, 두 번째는 특징 기반의 패턴인식 방법이 있다. 최대 우도추정 방식은 베이저안 추론을 통해 최적의 값을 얻을 수 있는 장점을 가지지만 높은 계산복잡도를 가지는 단점이 있다. 특징 기반의 패턴인식 방식은 입력 데이터 전처리, 특징추출, 마지막으로 분류 결정으로 진행된다. 본 논문에서는 DEEPSIG DATASET: RADIOML 2018.01A 데이터셋을 CNN (Convolutional Neural Network) 모델에 적용하여 변조 종류를 식별하는 방식을 제안하였다.

II. 시스템 모델

본 논문에서 신호의 자동 변조 분류를 위해 사용된 DEEPSIG DATASET: RADIOML 2018.01A에서 사용된 프레임 수는 1,572,864이며 각 프레임은 1024 샘플 신호로 구성되며, 변조 타입마다 98,304의 프레임이 사용되었다. SNR 구간은 -10 dB에서 20 dB이며 2 dB의 간격을 가진다. 수집된 데이터는 클로오프셋과 Rayleigh 페이딩 채널을 통과한 손상된 신호이며 사용된 중심주파수는 900MHz의 ISM 대역을 사용하였다.




그림 1 Example of system model

수신기에 k 번째 수신된 신호는 다음같이 표현할 수 있다. 채널 이득은 아래의 식으로 나타낼 수 있다.

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

여기서 α 은 다중 경로의 진폭이며, Δf 와 $\Delta \phi$ 는 캐리어 주파수와 위상의 오프셋, x_k 는 변조신호 그리고 n 는 백색가우시안잡음을 나타낸다. 수신된 신호는 데이터처리 부분에서 식2와 같이 RMS 정규화와 In-phase, Quadrature-phase 컴포넌트로 변환 뒤 딥러닝 기반 자동 변조 분류를 위해 전달된다.

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

III. 제안된 CNN 모델

일반적인 CNN 모델에서 하나의 합성곱 층에서 연산은 식3과 같이 표현할 수 있으며 스칼라 바이어스가 추가된다. 합성곱 층의 연산이 끝난 후 특징맵이 생성되며 이는 비선형 활성화함수 층을 통과하게 된다.

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

여기서 w_i 합성곱 커널 가중치를 의미하고, v_i 는 입력값을 의미한다. 제안하는 CNN은 SGDM (Stochastic Gradient Descent with Momentum) 최적화 기법을 사용하여 손실 값을 최적화하였으며, 여기서 사용되는 가중치(w)는 아래와 같이 나타낼 수 있다.

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

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

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

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.

제안된 CNN 모델은 표1에서 요약하였으며, 각각의 컨볼루션층은 배치 정규화 층과 ReLU 활성화함수 층과 조합되어 있다. 입력층에서 입력 크기는 2x1024가지며 채널 수는 1이다. 제안된 모델의 ResNet 모델의 skip connection 기법을 적용하였으며 pointwise 합성곱 층을 적용하여 학습과 라미터를 감소시켰다. 총 14개 컨볼루션층을 통해 특징맵을 추출하고 3개의 평균풀링층을 사용하여 학습되는 특징맵의 크기를 다운 샘플링 하였다. 여기서 FC (Fully Connection)층에 입력값이 전달되기 전 3x256 풀링 크기를 적용하여 128개의 채널만 연결되도록 하였다.

표 1 Configuration of CNN architecture

유형	출력크기	커널크기	파라미터 수
입력	2x1024	-	-
합성곱	6x1024x16	16x3x3	192
풀링	2x512x16	2x2	-
합성곱	6x512x32	2x2	-
풀링	3x256x32	2x2	-
블록1	3x256x32	32x1x1	1120
	3x256x8	8x3x1	792
	3x256x8	8x1x3	216
	3x256x32	32x1x1	352
블록2	3x256x64	64x1x1	2240
	3x256x16	16x3x1	3120
	3x256x16	16x1x3	816
	3x256x64	64x1x1	1216
블록3	3x256x128	128x1x1	8576
	3x256x32	32x3x1	12384
	3x256x128	128x1x1	4480
풀링	1x1x128	3x256	-
FC	24x128	-	3096
Softmax	24		

IV. 시뮬레이션 결과

본 논문에서 제안된 모델은 Matlab 2020b 프로그램을 통해 제안된 모델을 시뮬레이션 하였으며 결과는 그림 3, 4와 같이 비교결과를 Confusion Matrix 및 그래프로 나타내었다. 시뮬레이션을 위한 환경 설정은 최소 배치 크기 64, 최대 Epoch 45, 초기 학습비율 0.01 그리고 Epoch 40마다




그림 2 The accuracy performance comparison




그림 3 Confusion matrix for 24 modulation types

0.01 학습 비율을 낮추도록 하였다. 제안된 모델에서 시험 데이터셋에 대한 정확도는 SNR 10 dB에서 91.48%로 최신 모델 MCNet[2]보다 5.42% 향상된 정확도를 보였다.

V. 결론

본 논문에서는 자동 변조 분류를 위해 CNN 기법을 사용하여 변조 종류를 식별하는 모델을 제안하였다. 제안된 모델의 성능은 24개의 변조 종류를 예측하는데 SNR (Signal-to-Noise Ratio) 10dB에서 91.48% 정확도를 가지며 최신 모델 MCNet보다 5.42% 높은 정확도 성능을 나타내었다.

ACKNOWLEDGMENT

이 논문은 정부(교육과학기술부)의 재원으로 한국연구재단의 대학중점연구소 지원사업으로 수행된 연구임(2018R1A6A1A03024003).

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] T. Huynh-The, C. Hua, Q. Pham and D. Kim, "MCNet: An Efficient CNN Architecture for Robust Automatic Modulation Classification," IEEE Commun. Lett., vol. 4, no. 2, pp. 811-815, Api. 2020.