

CRANet기반 채널코딩 분류 연구

신새빈¹, 채명호², 임완수*³

¹금오공과대학교, ²국방과학연구소, ³성균관대학교

*wansu.lim@skku.edu

Channel Coding Classification using CRANet

Saebin Shin¹, Myoungcho Chae², Wansu Lim*³

¹Kumoh National Institute of Technology, ²Agency for Defense Development, ³Sungkyunkwan University

요약

본 논문은 딥러닝 기반 채널코딩 분류 기법을 제안한다. 딥러닝 모델은 CNN, Residual Connection, 그리고 Attention으로 CRANet을 구성하였다. CNN은 디지털 신호 특성을 반영하고 계산량을 줄이기 위하여 1DCNN을 사용하였고, 학습 효율성을 높이기 위하여 Residual Connection을 추가하였다. 마지막으로 채널코딩의 특징 추출 효과를 높이기 위하여 Attention 기법을 활용했다. 실험 결과 제안한 CRANet의 분류 정확도는 CNN대비 최대 18.91% 향상되었고, SNR 3dB부터 90% 이상의 분류 정확도를 보였다.

I. 서론

채널코딩은 무선 신호를 전송할 때 발생하는 오류를 감지 혹은 수정하는 기법으로서 디지털 통신 시스템에서 중요한 역할을 한다. 일반적으로 송신부는 채널코딩 파라미터를 지속해서 전송하지만, 무선 통신 자원(채널, 주파수)이 부족해지는 문제가 발생한다^[1]. 따라서, 무선 자원을 효율적으로 사용하기 위해 채널코딩 파라미터 정보 없이 신호를 복호화하는 연구가 활발히 진행되고 있다.

특히, 최근에는 딥러닝 기법을 채널코딩 분류에 적용하여 분류 정확도를 높이고 있으며, [1]은 CNN을 활용하여 LDPC, Convolutional, Turbo, Polar code를 분류하였다. [2]는 RNN과 CNN을 활용하여 LDPC, Convolutional을 분류하였다.

본 논문은 채널코딩 분류 정확도를 높이기 위한 CRANet을 제안한다. CRANet은 CNN, Residual Connection, 그리고 Attention으로 구성하였다. 복조된 후 0과 1로 구성된 디지털 정보를 입력 데이터로 사용하므로 1차원 데이터 처리에 효과적이고 시계열 데이터 분석에 용이한 1DCNN^[3-4]을 사용하였다. 그러나, CNN은 레이어가 깊어질수록 기울기 소실 혹은 기울기 폭주 문제가 발생할 수 있으므로 이러한 문제를 해결하기 위해 Residual Block^[5]을 사용했다. 또한, Attention Mechanism^[6-7]을 활용하여 중요 채널에 가중치를 부여함으로써 특징 추출 효과를 높였다.

II. CRANet 및 채널코딩 분류

CRANet은 CRA 모듈 3개와 Dense 층으로 구성하며, 그림1은 CRA 모듈이다. CRA 모듈의 첫 단계인 1DCNN은 커널 사이즈 (1 X 2)와 스트라이드 2를 이용하여 입력 데이터 혹은 특징맵의 크기를 절반으로 줄이고, 채널을 증가시킨다. 이때, 채널의 증가는 1번째 모듈의 경우 32개, 이후 4배씩 증가시킨다. 1DCNN 결과는 Channel Attention(CA)에 입력되어 GAP(Global Average Pooling)와 GMP(Global Maximum Pooling)가 적용된다. 두 풀링 층은 동일한 가중치를 사용하는 shared-MLP를 거쳐 더해진다. 이후 CA 입력과 곱해져 채널 간 중요도를 부여한다. CA 결과는 Spatial Attention(SA)에 입력되어 채널 축으로 GAP, GMP가 적용되어 2개의 채널로 생성된다. 다음으로 1DCNN을 통해 채널을 1개로 줄인다. 이후 SA의 입력과 곱해져 픽셀 간 중요도를 부여한다. 마지막으로 첫 단계의 1DCNN 결과와 SA 결과를 더하여 Residual Connection을 수행한다.

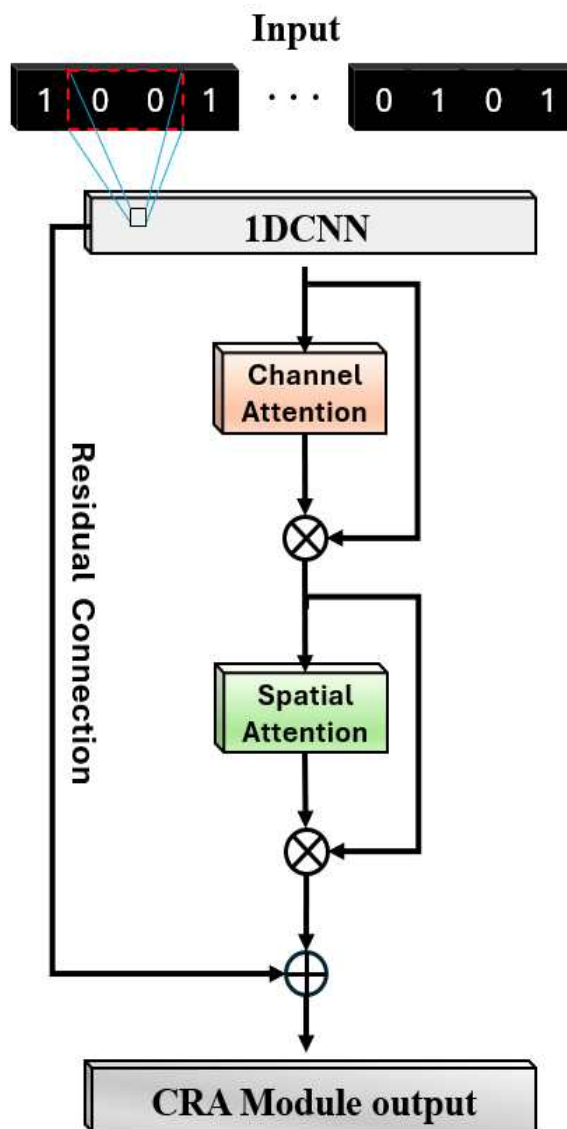


그림 1. CRA Module

표 1. 채널코딩 유형 및 파라미터

Coding types	Parameters
Convolution	(2,1,5)
BCH	(15,7)
Turbo	(7,4,3)
Polar	(8,4)
Hamming	(8,4)
Product	(8,4)
R-M	(2,4)
Golay	(23,12)

참고 문헌

[1] Sepehr Dehdashtian, Matin Hashemi, and Saber Salehkaleybar. "Deep-Learning-Based Blind Recognition of Channel Code Parameters Over Candidate Sets Under AWGN and Multi-Path Fading Conditions," IEEE Wireless Communications Letters, vol.10, no.5, pp.1041-1045, May. 2021.

[2] Boxiao Shen, Chuan Huang, Wenjun Xu, Tingting Yang, Shuguang Cui. "Blind Channel Codes Recognition via Deep Learning," IEEE Journal on Selected Areas in Communications, vol.39, no.8, pp.2421 - 2433, June. 2021

[3] Bjørn-Jostein Singstad and Christian Tronstad. "Convolutional Neural Network and Rule-Based Algorithms for Classifying 12-lead ECGs," 2020 Computing in Cardiology Conference, , pp. 1-4, Rimini, Italy, Sep. 2020.

[4] Shuzhan Huang, Jian Tang, Juying Dai and Yangyang Wang. "Signal Status Recognition Based on IDCNN and Its Feature Extraction Mechanism Analysis," Sensors, vol.19, no.9, Apr. 2019.

[5] Kaiming He, Xiangyu Zhang, Shaoqing Ren and Jian Sun. "Deep Residual Learning for Image Recognition," Proceedings of the IEEE conference on computer vision and pattern recognition, pp.770-778, Las Vegas, NV, USA, Dec. 2016.

[6] Jie Hu, Li Shen, Samuel Albanie, Gang Sun and Enhua Wu. "Squeeze-and-Excitation Networks," Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 7132-7141, Salt Lake City, UT, USA, June. 2018.

[7] Sanghyun Woo, Jongchan Park, Joon-Young Lee and In So Kweon, "CBAM: Convolutional Block Attention Module," Proceedings of the European conference on computer vision (ECCV), pp. 3-19, Munich, Germany, Sep. 2018.




그림 2. CRANet, CNN, LSTM의 정확도 비교

분류하는 채널코딩 유형은 표1에서 보듯이 블록 코드 6개 그리고 콘볼루션 코드 2개로, 총 8가지로 이루어진다.

데이터 생성은 SNR을 -5dB부터 20dB까지 1dB씩 증가하며, 각 SNR에서 채널코딩 유형별로 1000개 데이터를 생성했다. 데이터는 학습, 검증, 테스트를 위해 7:2:1 비율로 구분했다. 딥러닝 모델 생성 및 시뮬레이션은 pytorch 라이브러리로 진행하였다.

그림2는 SNR에 따른 채널코딩 분류 정확도이고, 벤치마크 모델로 CNN과 LSTM를 사용했다. 실험결과 CRANet, CNN 그리고 LSTM은 5dB에서 92.83%, 77.8% 그리고 36.1%의 정확도를 가진다. 특히 10dB에서 CRANet의 정확도는 CNN과 LSTM보다 각각 18.91%와 60.89% 높은 것을 알 수 있다. CRANet은 3dB부터 90%이상의 정확도를 보여주며 최대 93.9%의 분류 성능을 달성하였다. 또한 CRANet은 CNN보다 평균적으로 13.89%의 정확도 향상을 보이며, Residual Connection, Attention이 추가된 CRANet이 채널코딩 분류에서 효과적으로 작동함을 뒷받침해 준다.

III. 결론

본 논문은 채널코딩 분류를 위한 CRANet을 제안하였다. CRANet은 CNN에 Residual Connection와 Attention이 추가되어 채널코딩 분류 정확도를 향상한다. 본 실험에서는 -5dB부터 20dB까지의 SNR 환경에서 8개의 채널코딩 분류를 수행하였다. 실험 결과 제안한 CRANet이 0dB에서 CNN과 LSTM 대비 각각 약 18%와 60% 더 높은 정확도를 보였다. 이를 통해 CRANet이 다양한 채널코딩 분류에 있어 강력한 성능을 보임을 입증하였다. 따라서 CRANet은 채널코딩 파라미터 없이 복호화하는데 이바지할 것으로 기대된다.

ACKNOWLEDGMENT

이 논문은 방위사업청의 재원으로 국방과학연구소의 지원을 받아 수행된 연구임 (311JJ5-912967201)