

부호화된 신호의 자동 검출을 위한 딥러닝 모델 설계

유소영, 김정현

순천향대학교, 세종대학교

yooso0731@sch.ac.kr, j.kim@sejong.ac.kr

A new design of deep learning model for automatic detection of coded signals

Soyoung Yoo, Junghyun Kim

Soonchunhyung Univ., Sejong Univ.

요약

본 논문은 부호화된 신호가 수신에 성공하였는지 자동으로 검출하는 새로운 딥러닝 모델을 제안한다. 기존 길쌈 부호로 부호화된 신호의 자동 검출을 위한 딥러닝 모델 대비 성능을 높이기 위하여 여러 층의 1D-CNN으로 구성된 비대칭 오토 인코더에 숏컷을 추가한 신경망 모델을 새롭게 설계하였다. 제안 모델에 대해 정상 데이터와 비정상 데이터를 포함하여 테스트한 결과 SNR이 9dB 이상인 영역에서 90% 이상의 높은 분류 정확도를 보였다.

I. 서론

기존 무선 통신 시스템에서는 디코딩 성공 여부 판단을 위해 순환 중복 검사 기법을 사용한다. 순환 중복 검사 기법은 오류 여부를 확인할 수 있는 체크 값인 CRC를 데이터에 붙여 부호화한 뒤 무선 채널을 통해 전송하고 수신기에서 수신된 신호를 복호화한 뒤 획득한 CRC 값을 이용하여 수신 성공 여부를 확인하는 방식이다. 이 방법은 검출 능력이 우수하지만 수신 신호를 복호화하기 전에는 수신 성공 여부를 판단할 수 없고, 매 전송마다 CRC를 위한 추가적인 자원 사용이 필요하다는 한계점을 가진다. 따라서 수신 성공 여부의 빠른 판단과 무선 자원 사용의 효율성을 위해 새로운 복조 및 디코딩 성공 여부 자동 검출 기술에 대한 연구가 필요하다.

최근 오토인코더를 활용하여 길쌈 부호로 부호화된 신호를 자동 검출할 수 있는 기법[1]이 제안되었다. 오토인코더[2]는 인공 신경망을 사용한 비지도 학습 기법의 하나로 차원 축소[3], 잡음 제거[4], 이상 탐지[5-7] 등에 사용된다. 오토인코더를 구성하는 두 개의 블록 중 인코더는 입력 데이터의 특성을 잠재 표현에 인코딩하고 디코더는 인코딩된 데이터를 입력 데이터와 동일하게 재구성한다. 이러한 특징을 활용하여 부호화된 신호의 패턴을 압축하여 학습하고 이를 바탕으로 수신 신호로부터 패턴 도출 가능성을 확인하여 수신 성공 여부를 판단하는 모델을 설계할 수 있다.

본 논문에서는 [1]에서 제안된 모델의 성능을 개선하기 위하여 여러 층의 1D-CNN으로 구성된 오토인코더에 숏컷을 추가하고 멀티태스킹 러닝을 통해 학습 효과를 극대화하였다. 또한 다양한 변조 기법과 함께 사용할 수 있도록 복소수 입력을 처리할 수 있는 신경망을 설계하였다.

II. 본론

본 논문에서 제안하는 부호화된 신호의 수신 성공 여부 검출 시스템이 그림 1에 표현되어 있다. 시스템 내부의 오토인코더는 정상 케이스에 해당하는 데이터와 비정상 케이스에 해당하는 데이터를 모두 사용하여 정상 케이스는 재구성 손실 값을 최소화하고 비정상 케이스는 재구성 손실 값을 최대화하는 방향으로 학습하였다. 또한 두 가지 케이스 모두에 대해 해당 케이스 검출 분류를 위한 손실 값을 추가로 정의하여 재구성 손실 값과 함께 멀티태스킹 러닝을 적용하였다. 학습 완료된 모델은 정상 및 비정상 데이터에 대해 이상 탐지를 진행한다. 정상 데이터는 K비트의 정보 비트로 구성되고 이를 블록 부호로 N비트 부호어로 부호화한 뒤 M개의 변조 심볼로 변조한 신호이다. 비정상 데이터는 N비트의 랜덤 비트를 발생시키고 부호어에 해당하는 경우는 제외한 뒤 M개의 변조 심볼로 변조한 신호이다.

그림 2는 제안하는 자동 검출을 위한 비대칭 오토인코더 구조의 딥러닝 모델이다. 인코더와 디코더는 모두 필터 크기가 1인 1차원 컨벌루션 층을 여러 개 쌓은 형태로 구성하였고, 인코더와 디코더를 연결하는 숏컷을 추가하여 성능을 향상시켰다. 인코더는 순서대로 필터가 32, 16, 4개인 층으로 구성되며 디코더는 잠재 표현 층을 기준으로 필터가 16, 4개인 층으로 구성하였다. 이후 2차원 데이터를 1차원으로 펼치는 flatten 층을 거쳐 재구성 데이터가 출력되는 재구성 층과 최종 분류 예측값이 출력되는 분류층으로 구성하였다. 재구성 층과 분류 층의 활성화함수는 sigmoid를 사용하고 이외의 모든 층에서 활성화함수는 tanh로 설정했다. 제안 모델의 성능을 나타내는 지표로는 정상 케이스와 비정상 케이스에 대한 분류 정확도를 사용했다.

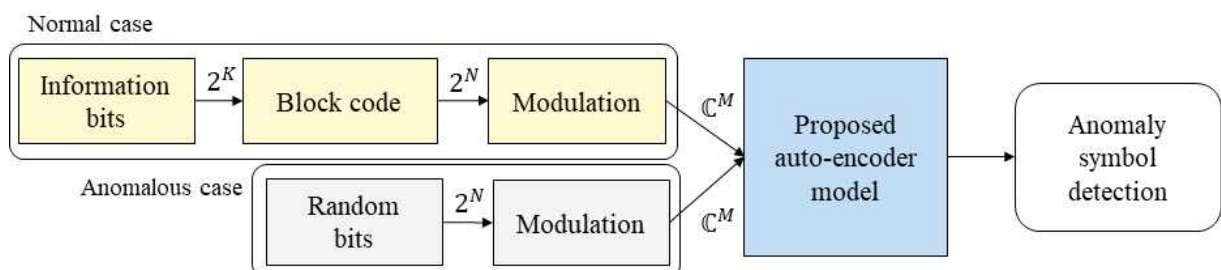


그림 1 제안하는 딥러닝 기반 자동 검출 시스템

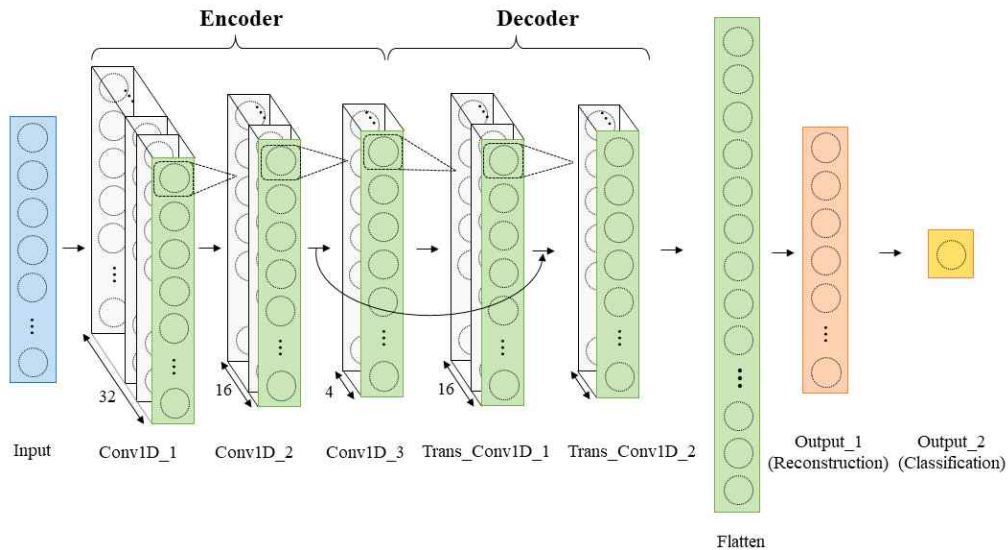


그림 2 제안하는 자동 검출을 위한 딥러닝 모델의 구조

성능 검증을 위해 앞서 정의한 정보 비트, 부호 비트, 변조 심볼 수를 각각 $K=4$, $N=8$, $M=4$ 인 경우에 대해 실험하였다. 즉, 확장 해밍 부호와 4QAM 변조를 사용하였다. 이때 손실 함수로 binary cross-entropy, 최적화 알고리즘으로는 학습률이 0.001인 Adam 알고리즘을 사용했다. 또한 학습은 1000 에포크 반복 학습을 수행했다. 잡음이 존재하는 채널 상황을 고려하여 신호 대 잡음비(Signal-to-Noise Ratio, SNR)를 0dB부터 11dB까지 1dB 간격으로 키우며 성능을 확인했다. 표1은 SNR에 따른 분류 정확도를 나타낸 것이다. SNR이 0dB일 때 가장 낮은 분류 정확도인 약 51%를 보였고, 9dB부터 90% 이상의 높은 분류 정확도를 보였다.

표 1. SNR에 따른 분류 정확도

SNR	Accuracy (%)	SNR	Accuracy (%)
0	50.58	6	74.17
1	51.31	7	79.60
2	54.13	8	85.10
3	56.23	9	91.50
4	61.40	10	93.63
5	66.96	11	96.04

그림 3은 SNR이 11dB인 환경에서 혼동행렬을 나타낸 것이다. 이를 통하여 제안한 모델이 정상 케이스와 비정상 케이스 모두에 대해 높은 확률로 자동 검출에 성공하고 있음을 확인할 수 있다.

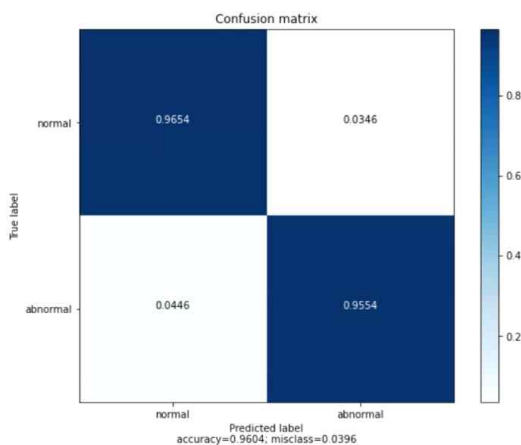


그림 3 제안 모델의 혼동행렬의 예(SNR=11dB)

III. 결론

본 논문에서는 부호화된 신호의 복조 및 디코딩 성공 여부를 자동으로 검출하는 잔여 오토인코더 기반 이상탐지 모델을 제안하였다. 제안한 모델은 기존의 순환 중복 검사 기법과는 달리 수신 성공 여부를 위하여 사전 복조 과정을 수행할 필요가 없고 수신 신호를 신경망에 통과시켜 즉시 값을 확인함으로써 수신 성공 여부를 판단할 수 있다. 또한 최근 제안된 딥러닝 기반 자동 검출 모델에서 사용한 오토인코더 구조를 개선하고 멀티태스킹 러닝을 적용하여 더욱 좋은 성능을 얻을 수 있음을 보였다. 향후 연구로는 보다 긴 길이의 부호로 부호화된 신호에 대한 자동 검출과 높은 차수로 변조된 신호에 대한 다양한 성능 검증과 설계된 딥러닝 모델의 학습 및 추론 복잡도에 대한 분석을 고려할 수 있다.

참 고 문 헌

- [1] 유소영, 김정현. "길쌈 부호로 부호화된 신호의 딥러닝 기반 자동 검출," 한국통신학회 하계종합학술발표회, Jun, 2022.
- [2] Rumelhart, D. E., Hinton, G. E., & Williams, R. J. "Learning internal representations by error propagation," California Univ San Diego La Jolla Inst for Cognitive Science, 1985.
- [3] Wang, W., Huang, Y., Wang, Y., & Wang, L. "Generalized autoencoder: A neural network framework for dimensionality reduction." In Proceedings of the IEEE conference on computer vision and pattern recognition workshops, pp. 490-497, 2014.
- [4] Vincent, P., Larochelle, H., Bengio, Y., & Manzagol, P. A. "Extracting and composing robust features with denoising autoencoders." In Proceedings of the 25th international conference on Machine learning, pp. 1096-1103. Jul, 2008.
- [5] Farina, M., Nakai, Y., & Shih, D. "Searching for new physics with deep autoencoders." Physical Review D, 101.7: 075021, 2020.
- [6] Hajer, J., Li, Y. Y., Liu, T., & Wang, H. "Novelty detection meets collider physics." Physical Review D 101.7: 076015, 2020.
- [7] Finke, T., Krämer, M., Morandini, A., Mück, A., & Oleksiyuk, I. "Autoencoders for unsupervised anomaly detection in high energy physics." Journal of High Energy Physics, pp. 1-32, 2021.