

비트 오류율 감소를 위한 오토 인코더 기반 통신 시스템 설계

한 석주*, 하 정석^o

Autoencoder Based Communication Systems with Low Bit-Error Rate

Seokju Han*, Jeongseok Ha^o

요 약

본 논문은 비트 오류율 감소를 위한 오토인코더 기반 통신 시스템을 제안한다. 기존 오토인코더 기반 통신 시스템은 end-to-end 학습을 통해 높은 블록 오류 정정 성능을 보이거나 학습 과정에서 메시지 간 해밍 거리가 반영되지 못해, 블록 오류 발생 시 높은 비트 오류 개수를 보인다. 본 논문에서는 손실 함수 및 학습 과정에서 메시지 간 해밍 거리를 반영하여 오토인코더 기반 통신 시스템의 비트 오류율을 감소시킨다. 시뮬레이션 결과를 통해 제안하는 방법은 블록 오류율의 손실 없이 기존 오토인코더의 비트 오류율을 감소시킬 수 있다.

Key Words : communication, deep learning, neural network, autoencoder, bit-error rate

ABSTRACT

This paper proposes an autoencoder-based communication (AEC) system with a low bit error rate. Existing AEC systems show a good block error rate performance through end-to-end learning. However, since the Hamming distance between messages is not considered in the learning process, it results in a large number of bit errors when a block error occurs. In this paper, we improve the bit error

correction performance of the AEC system by re-designing the loss function by taking into account the Hamming distance between messages. Simulation results show that the proposed scheme significantly reduces the bit error rate of the existing AEC without loss of the block error rate.

I. 서 론

딥러닝 (Deep learning) 기술의 발달은 다계층의 신경망을 활용한 데이터로부터의 학습을 통해 사물 인식, 자연어 처리 등 다양한 분야에서 많은 발전을 이룩하고 있다. 최근 이러한 성공에 힘입어 통신 분야에서 채널 부호^[1,2], 채널 추정^[3], 통신 시스템 설계^[4-6] 등 기존 통신 기술들에 딥러닝을 적용하려는 노력들이 계속되고 있다^[1-6]. 딥러닝 기반 통신 기술은 기존의 수학적 모델링을 통해 해결하기 어려웠던 통신 문제를 실제 데이터의 비선형성을 반영하여 주어진 데이터로부터 학습을 바탕으로 모델링한다. 또한, 딥러닝에서 사용되는 심층 신경망 (deep neural network)은 높은 병렬 연산 속도로 주어진 문제에 대한 고속 연산을 제공한다. 특히, 오토인코더 (autoencoder) 와 같은 기술을 활용해 채널 부호, 변조와 같은 개별 블록 단위의 설계를 개선한 end-to-end 통신 시스템 통합 최적화를 통해 전체 통신 시스템의 성능을 향상시키려는 연구가 활발히 진행 중이다. 오토인코더는 주어진 입력과 동일한 값을 출력할 수 있도록 학습되는 신경망 구조로 학습을 통해 기존 데이터에서 중요한 정보를 추출할 수 있으며, 적용 분야에 따라 잡음이 더해진 정보에서 기존 정보를 다시 복구해내는 데에 활용된다. 기존 통신에서 잡음이 더해진 채널을 통해 전송된 데이터를 본래의 전송 데이터로 복구하는 시스템은 이러한 오토인코더 구조를 활용하여 심층 신경망을 통해 수신기와 송신기를 동시에 최적화시킬 수 있다^[4].

기존 오토인코더 기반 통신 시스템은 블록 단위의 오류율 (블록 오류율)에 최적화되어 학습된다. 이는 높은 블록 오류 정정 성능을 갖지만, 블록 오류 발생 시 오류 블록 내 많은 비트 오류가 발생하고 이러한

* 이 논문은 2020년도 정부(미래창조과학부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. NRF-2018R1A2B6003474)

• First Author : (ORCID:0000-0001-9453-7033)Korea Advanced Institute of Science and Technology Department of Electrical Engineering, enfgui@kaist.ac.kr, 학생(박사), 학생회원

^o Corresponding Author : (ORCID:0000-0003-1262-151X)Korea Advanced Institute of Science and Technology Department of Electrical Engineering, jsha@kaist.edu, 정교수, 종신회원

논문번호 : 202012-324-A-LU, Received December 23, 2020; Revised January 28, 2021; Accepted January 29, 2021

문제는 발생한 블록 오류에 대한 추가적인 오류 정정 과정에서 다수의 비트 오류로 인해 본래의 메시지로의 오류 정정의 어려움을 겪는다. 이에 본 논문에서는 기존 오토인코더 기반 통신 시스템의 높은 블록 오류 정정 성능을 유지하며, 비트 오류율을 감소시킬 수 있는 오토인코더 기반 통신 시스템을 제안한다. 기존 오토인코더를 기반으로 전송 메시지와 해밍 거리 (Hamming distance)를 고려하여 학습 라벨 값을 재정의하고 그에 따른 손실함수의 재설계를 통해 해밍 거리가 가까운 메시지들에 가중을 둔 학습을 진행한다. 이를 통해 기존 오토인코더 기반 통신의 높은 블록 오류 정정 성능을 유지하며, 비트 오류율을 감소시킬 수 있다.

II. 오토인코더 기반 통신 시스템

본 논문에서 사용하는 오토인코더 기반 통신 시스템^[1]의 구조는 그림 1과 같이 송신층, 채널, 수신층으로 구분되어 하나의 심층 신경망을 형성하며 입력 비트의 길이 k 와 인코딩된 데이터의 길이 n 에 따라서 (n, k) 의 형태로 표현한다. 송신층에서는 전송할 메시지 $s \in \{1, 2, \dots, M\}$, $M = 2^k$ 를 one-hot 벡터의 형태 \mathbf{t} 로 표현하여 네트워크의 입력으로 사용한다. 입력 값은 다수의 완전 연결 (fully connected, FC) 층을 통해 전송 벡터로 인코딩 된다. 송신기는 신호의 송신 이전에 평균 전력 제한을 만족시키기 위해 전력 제한 층을 거친다. 인코딩 된 데이터 \mathbf{x} 는 채널을 통과하여 채널 잡음이 더해진 수신층의 입력 \mathbf{y} 로 들어오며, 수신층에서는 다수의 FC층을 통해 본래의 메시지로 복호한다. 복호된 메시지는 개별 메시지의 전송 확률 값 $\Pr(s = i | \mathbf{y})$ 의 형태로 표현하기 위해 Softmax 활성화 함수를 통해 확률의 형태로 표현된다. 오토인코더의 복호결과는 출력된 확률 중 가장 높은 값에 해당하는 메시지를 복호 결과로 출력한다.

오토인코더의 통합된 심층 신경망 구조는 주어진




그림 1. 오토인코더 기반 통신 시스템
Fig. 1. AEC Systems

학습 데이터로부터 계산된 손실 함수의 기울기 (gradient)의 전파를 통해 수신기와 송신기를 동시에 최적화할 수 있다. 학습에 사용되는 손실함수는 송신 메시지로의 올바른 복호를 위해 블록 오류율을 최소화시키도록 설정된다. 기존 오토인코더 기반 통신 시스템의 손실 함수는 식 (1)의 categorical cross entropy 함수를 활용한다.

$$L(s) = - \sum_{j=1}^M t_j \log(f(s)_j) \quad (1)$$

여기서 $\mathbf{t} = (t_1, t_2, \dots, t_M)$ 는 학습에 사용되는 라벨을 나타내고, $f(s) = (f(s)_1, f(s)_2, \dots, f(s)_M)$ 는 입력 s 에 대한 오토인코더 출력 값을 나타낸다.

III. 비트 오류율 감소를 위한 오토인코더 모델

본 논문에서는 비트 오류율을 최적화할 수 있는 오토 인코더의 학습 방식을 제안한다. 기존 오토인코더의 손실함수는 블록 오류율을 최소화시키기 위해 categorical cross entropy 손실 함수를 사용한다. 이는 전송 메시지와 동일한 메시지로 복호할 수 있도록 학습을 진행하지만, 학습 과정에서 메시지 간 해밍 거리가 고려되지 않아, 오류가 발생한 경우 비트 오류 수에 관계없이 무작위적 오류가 발생하고 이는 비트 오류율의 증가로 이어지게 된다.

본 연구에서는 전송 메시지와 복호 메시지 간 해밍 거리를 반영한 학습을 통해 오토인코더 기반 통신 시스템의 비트 오류 성능을 향상시킨다. 전송 메시지와 복호된 메시지 간의 해밍 거리는 비트 오류의 수와 동일하기 때문에 학습 과정에서 사용되는 손실함수에 메시지 간의 해밍 거리를 반영시킴으로써 비트 오류 성능을 개선할 수 있다. 기존 one-hot 기반의 라벨링은 전송 메시지의 위치에 한해서 1의 값을 갖는다. 이는 실제 전달된 메시지의 위치만을 나타내며, 해밍 거리가 인접한 메시지에 대한 정보를 제공하지 못한다. 따라서 본 연구에서는 오토인코더의 학습에 사용되는 라벨의 값을 재조정하여 전송 메시지 s 와 복호 메시지 j 의 해밍 거리를 반영한다. 학습 라벨 값은 식 (2)로 정의된다.

$$t_j = \alpha^{d_H(s,j)}, j \in \{1, 2, \dots, M\} \quad (2)$$

여기서 $0 < \alpha < 1$ 는 해밍 거리에 따른 메시지 간 가중을 두는 파라미터이다. 제안하는 오토인코더의 학습 라벨은 전송된 메시지와 해밍 거리가 가까울수록 큰 값을 갖도록 설정되어 블록 오류가 발생한 상황에서 해밍 거리가 더 가까운 메시지로 복호될 수 있도록 학습된다. 학습은 식 (3)에서 정의된 수신기 출력 값 $f(s)$ 에 대한 평균 제곱 오차 손실 함수를 사용한다.

$$L(s) = \frac{1}{M} \sum_{j=1}^M (t_j - f(s)_j)^2 \quad (3)$$

본 연구에서 사용된 오토인코더 모델은 Keras를 활용하여 구현되었으며, AWGN 채널 환경에서 실험이 진행되었다. 학습 데이터는 $E_b/N_0=4\text{dB}$ 의 채널 환경에서 무작위로 발생시킨 메시지 벡터를 전송하여 2×10^4 개의 샘플을 수집하였다. 모델의 학습 파라미터는 학습률(learning rate) 0.001, 학습 배치의 크기(batch size) 32로 설정하고, Adam optimizer를 활용하여 학습이 진행되었다. 사용된 오토인코더 모델의 송신층과 수신층은 각각 2개의 FC 층로 구성되어 개별 층은 입력값 M 과 동일한 개수의 은닉 유닛을 갖도록 설계되었다.

실험은 $(n,k) = (4,4)$ 와 $(6,6)$, $(8,8)$ 의 환경에서 기존 일반적인 통신 시스템에서의 ML 복호 환경(uncoded)과 일반적인 오토인코더 기반 통신 시스템^[4](AE), 그리고 제안하는 오토인코더 모델(AE-B)의 성능을 비교한다. 그림 2는 AWGN 채널에서 $(4,4)$ 오토인코더의 비트 오류율(BER)과 블록 오류율(BLER) 성능을 나타낸다. 실험에는 $\alpha = 0.2$ 의 값이




그림 2. $(4,4)$ 오토인코더의 오류율 성능 (AWGN 채널)
Fig. 2. Error rate performance of $(4,4)$ AEC (AWGN)

사용되었다. 그래프의 결과에 따르면 제안하는 알고리즘은 기존 오토인코더와 동일한 블록 오류율로 기존 일반적인 통신시스템보다 개선된 성능을 가짐을 확인할 수 있다. 하지만 제안하는 모델은 손실함수 및 모델 재설계를 통해 비트 오류율을 15% 이상 개선함을 확인할 수 있다. 학습된 송신단 신호점 (signal constellation)은 그림 6의 형태로 관찰된다. 제안하는 알고리즘의 사용을 통해 기존 오토인코더 기반 통신 시스템과 다른 형태의 신호점으로 학습됨을 확인할 수 있다. 그림 3, 4는 $(6,6)$ 과 $(8,8)$ 오토인코더 환경에서 각각 $\alpha = 0.1$ 및 0.15 의 값을 사용했을 때의 오류율 성능으로, 마찬가지로 기존 오토인코더와 동일 블록 오류율로, 비트 오류율을 20% 이상 감소시킴을 확인하여 제안하는 오토인코더 모델이 블록 오류율의 손실 없이 비트 오류 성능을 개선함을 검증한다.

다양한 채널 환경을 고려하기 위해 레이더 채널 환

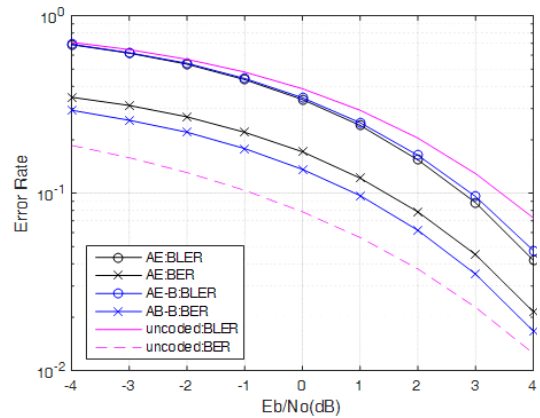


그림 3. $(6,6)$ 오토인코더의 오류율 성능 (AWGN)
Fig. 3. Error rate performance of $(6,6)$ AEC (AWGN)

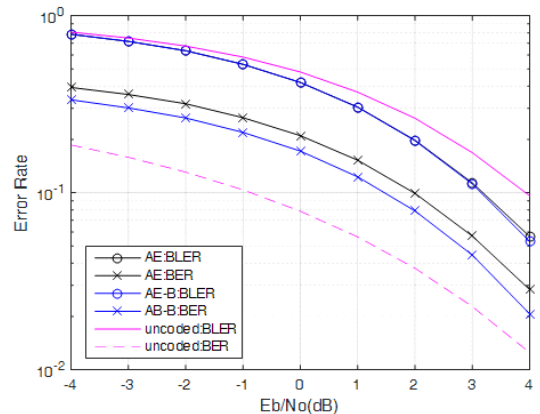


그림 4. $(8,8)$ 오토인코더의 오류율 성능 (AWGN)
Fig. 4. Error rate performance of $(8,8)$ AEC (AWGN)

경에서 제안하는 알고리즘의 성능을 검증하였다. 레이더 채널은 AWGN 채널 환경에 낮은 확률 p 로 높은 분산의 레이더 잡음 $w \sim N(0, \sigma_r^2)$ 이 더해지는 특성을 가지며, 실험에는 $p = 0.05$, $\sigma_p^2 = 2$ 의 환경에서 진행되었다. 그림 5의 결과에 따르면, 레이더 채널 환경에서 오토인코더 기반 통신시스템이 기존 일반적인 통신 시스템의 블록 오류율 성능을 개선하며, 제안하는 알고리즘의 비트 오류율 성능은 기존 오토인코더의 성능을 17%이상 개선함을 확인할 수 있다. 이를 통해 다양한 채널 환경에서 제안하는 알고리즘을 통해 오토인코더 기반 통신 시스템의 비트 오류율을 감소시킬 수 있음을 나타낸다.

IV. 결론

본 논문에서는 비트 오류율의 감소를 위한 오토인코더 기반 통신 시스템을 설계한다. 제안하는 모델은 학습 라벨 값과 손실 함수에 전송 메시지와 복호 메시지 간의 해밍 거리를 반영하여, 기존 오토인코더 기반 통신 시스템의 높은 블록 오류 정정 성능을 유지하며 비트 오류율을 감소시키는 학습 방식을 제안한다. 시뮬레이션을 통해 제안하는 모델의 성능 개선을 AWGN 채널 및 레이더 채널 등 다양한 채널 환경에서 확인하여, 낮은 블록 오류율 및 비트 오류율을 요구하는 통신 환경에서 사용 가능할 것으로 기대된다.

References

- [1] E. Nachmani, Y. Beery, and D. Burshtein, "Learning to decode linear codes using deep learning," in *2016 54th Annu. Allerton Conf. Commun., Control, and Comput. (Allerton)*, pp. 341-346, Sep. 2016.
- [2] T. Gruber, S. Cammerer, J. Hoydis, and S. t. Brink, "On deep learning-based channel decoding," *2017 51st Annu. Conf. Inf. Sci. and Syst. (CISS)*, pp. 1-6, Mar. 2017.
- [3] M. Soltani, V. Pourahmadi, A. Mirzaei, and H. Sheikhzadeh, "Deep learning-based channel estimation," *IEEE Commun. Lett.*, vol. 23, no. 4, pp. 652-655, Apr. 2019.
- [4] T. O'Shea and J. Hoydis, "An introduction to deep learning for the physical layer," *IEEE Trans. Cogn. Commun. and Netw.*, vol. 3, no. 4, pp. 563-575, Oct. 2017.
- [5] A. Felix, S. Cammerer, S. Dörner, J. Hoydis, and S. ten Brink, "OFDM-autoencoder for end-to-end learning of communications systems," in *2018 IEEE 19th Int. Wkshp Sign. Process. Advances in Wireless Commun. (SPAWC)*, pp. 1-5, Jun. 2018.
- [6] S. Han and J. Ha, "Deep neural decoder for rate-compatible codes," in *Proc. Symp. KICS*, pp. 642-643, Youngpyeong, Korea, Feb. 2020.

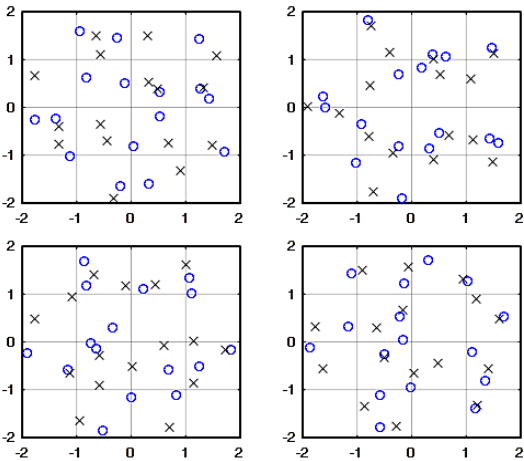


그림 5. (4,4) 오토인코더의 송신단 신호점 (o: AE-B, x: AE)
Fig. 5. Constellation mapping of (4,4) AEC (o: AE-B, x: AE)




그림 6. (8,8) 오토인코더의 오류율 성능 (레이더 채널)
Fig. 6. Error rate performance of (8,8) AEC (Radar channel)