



오토인코더 기반 잡음 제거 모듈이 결합된 HGN 복호기와 Conventional Polar SCL 복호기 간의 성능 및 복잡도 비교

한소영, 김정현*, 송홍엽
연세대학교, 세종대학교*

sy.han@yonsei.ac.kr

j.kim@sejong.ac.kr

hysong@yonsei.ac.kr

2022.09.28.



목차

I. 서론

- 딥러닝을 적용한 오류정정부호 복호 기법
 - Hyper-Graph-Network Decoder
- Neural network channel denoiser
- Denoising autoencoder

II. 본론

- 제안한 수신기 학습 모델 구조
- 제안한 autoencoder denoiser 구조
- 복잡도 비교
- Polar(64,48)의 비트 오류율 및 블록 오류율 성능 비교

III. 결론


IV. 참고문헌



오류정정부호 복호 기법

- 기존 오류정정부호 복호 기법

- Belief Propagation(BP)
- Min-sum algorithm



- 딥러닝을 적용한 오류정정부호 복호 기법

Neural BP decoding [1]

Neural-offset min-sum decoding [2]

Hyper-Graph-Network (HGN) decoder [3] → 제안 모델에 사용

[1] Nachmani, E., Be'ery, Y., and Burshtein, D, "Learning to decode linear codes using deep learning," in Proc. Annu. Allerton Conf. Commun., Control, Comput, Sep. 2016, pp. 341–346.

[2] Lugosch, L., and Gross, W. J. "Neural offset min-sum decoding," in Proc. IEEE Int. Symp. Inf. Theory (ISIT), Jun. 2017, pp. 1361–1365.

[3] Nachmani, E., and Wolf, L. "Hyper-graph-network decoders for block codes," in Proc. Advances in Neural Inform. Proces. Systems (NIPS), 2019, pp. 2329–2339.




Hyper-Graph-Network (HGN) decoder

▪ HGN decoder [3]


- “hypernetwork” 기법[4] 기반
- Variable 노드를 네트워크 g 로 대체,
그 가중치를 추가적인 네트워크 f 를 사용하여 예측

→ 다양한 code family에서 기존 learning-based 복호 성능을 능가

BUT, 충분한 성능을 얻기까지 긴 학습시간 요구




- Tanner graph for a linear block code with $n=5, k=2, d_v = 2$



- Trellis graph (two iteration)


Neural network channel denoiser

- CNN, MLP, RNN 기법을 사용한 neural network (NN) channel denoiser를 제안 [6] - for BCH codes
- CNN, MLP, RNN 의 NN denoiser 모델에 residual connection을 추가하여 향상된 성능을 보임[7] - for Polar codes



(a) BER performance

BCH(15,7,2) BER performance [6]

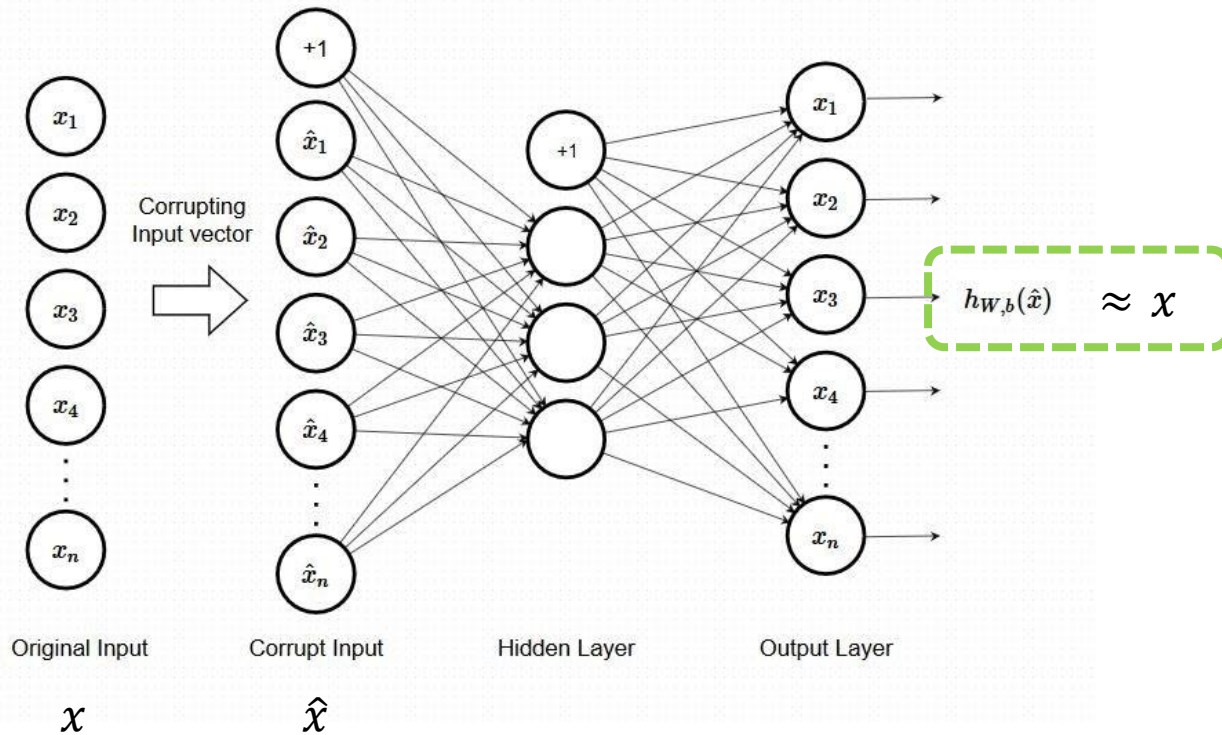


System model of NN denoiser for BCH codes [7]

[6] Zhu, H., Cao, Z., Zhao, Y., and Li, D, "A novel neural network denoiser for BCH codes," in Proc. IEEE/CIC Int. Conf. on Commun. in China (ICCC), Aug. 2020, pp. 272–276.

[7] Zhu, H., Cao, Z., Zhao, Y., and Li, D, "Learning to denoise and decode: A novel residual neural network decoder for polar codes," IEEE Trans. Veh. Technol., vol. 69, no. 8, pp. 8725–8738, Aug. 2020.

Denoising Autoencoder

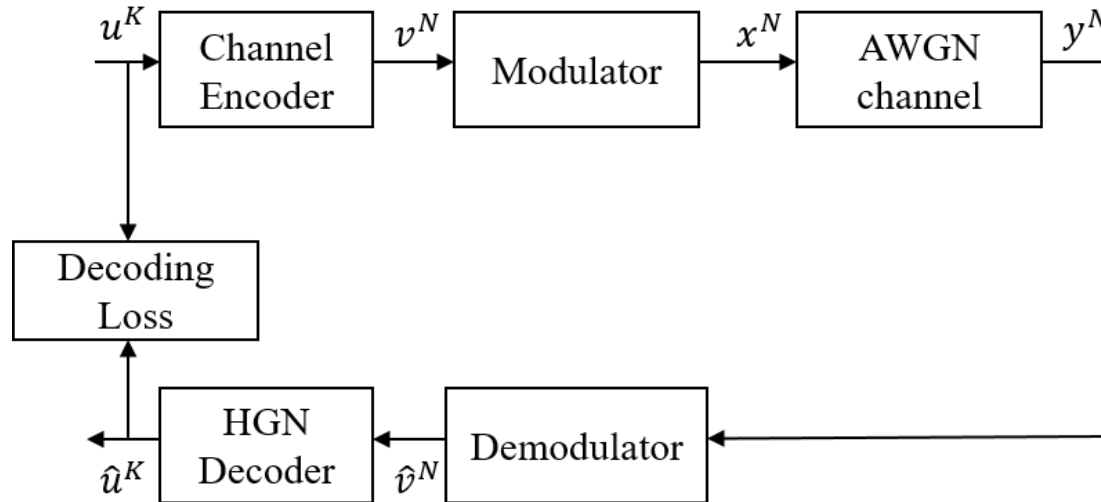


- 압축된 특성을 효과적으로 추출하는 Autoencoder 특성 이용
→ **노이즈 제거에 사용**
- 이미지 잡음 제거, 음성 신호 추출 등 노이즈 제거 분야에서 뛰어난 성능을 보임



Hyper-graph-network 복호기 학습 모델

- 기존 송수신기 모델 [3]



[3] Nachmani, E., and Wolf, L. "Hyper-graph-network decoders for block codes," in Proc. Advances in Neural Inform. Proces. Systems (NIPS), 2019, pp. 2329–2339.

제안한 수신기 학습 모델

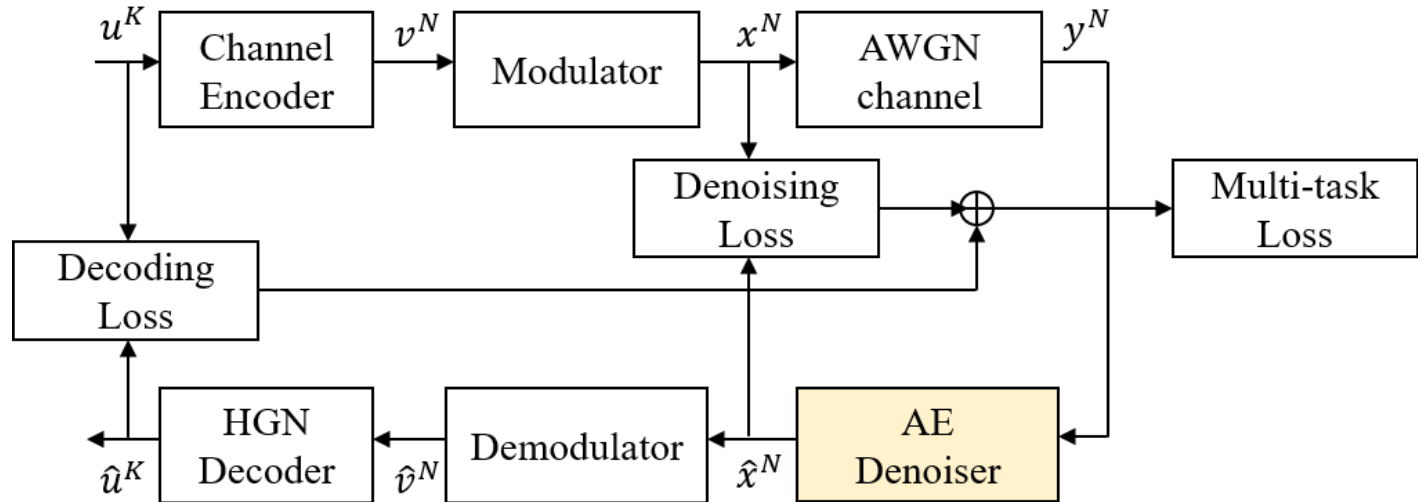


그림 1. 수신기 학습 모델 구조 [5]

▪ Multi-task Loss (L) [5]


$$\bullet L = w_1 L_{Denoise} + w_2 L_{Decode} \quad (1)$$

→ L 을 최소화하는 방향으로 jointly 학습

[5] 한소영, 김정현, 송홍엽, "Denoising autoencoder를 이용한 새로운 구조의 채널 denoiser." 한국통신학회 학술대회논문집 2022.6



Denoising autoencoder channel denoiser



- Encoding part
 - 2개의 1D-convolutional layer
 - 채널 개수 : 15, 7
- Decoding part
 - 2개의 1D-transposed convolutional layer
 - 채널 개수 : 15, 1
- Filter size : 3x1



수신기 학습에 사용된 하이퍼 파라미터

파라미터	설정값
배치 크기	500
손실함수	Mean squared error(MSE)
최적화 방법	Adam optimizer, 학습률 = 10^{-5}
에포크 수	5



복잡도 비교

- Polar SCL decoding과의 복잡도 비교 (연산량 비교)

- SCL decoder [3]

$$L \cdot N \cdot \log_2 N + (N - M) \cdot L \cdot \log_2 2L \\ \rightarrow \mathcal{O}(LN \log_2 N)$$

- Our model

$$\mathcal{O}(EB(l_{max} \cdot N^3 d_v^3 + 4NC_1C_2))$$

↗ ↖

HGN Decoder **AE Denoiser**

N : Code length (ex. 64)

M : Number of parity bits (ex.16)

L : List size (ex. 4)


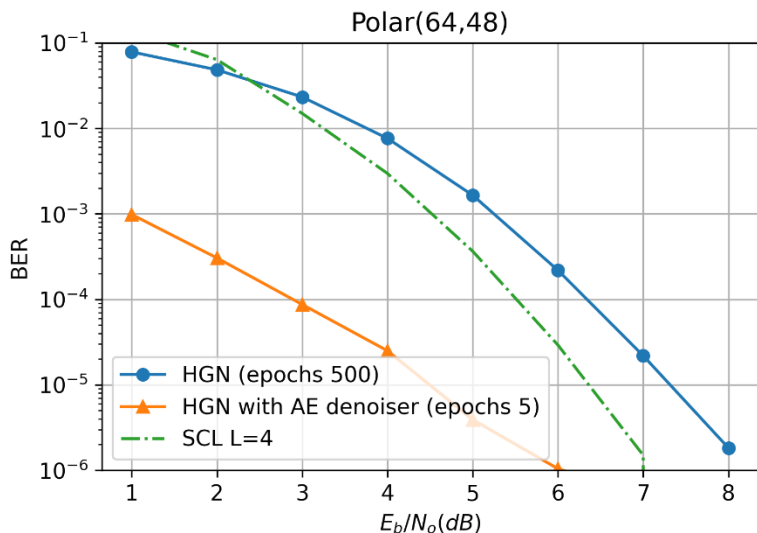
B : Batch size (ex. 500)

E : Number of epoch (ex. 5)

[3] Sybis, Michal, et al. "Channel coding for ultra-reliable low-latency communication in 5G systems.", *2016 IEEE 84th vehicular technology conference (VTC-Fall)*. IEEE, 2016.



Polar (64,48) BER, BLER 성능 비교



■ 실험 환경

- 학습 & 테스트 : 랜덤 비트에 generator matrix를 곱하여 모든 가능한 codeword를 생성하고 노이즈를 더하여 실험

■ 실험 결과

- 제안 기법이 **denoiser 없는 HGN 복호기[3]** 대비 **1%의 에포크 만으로 향상된 성능**을 보임
→ BER 10^{-4} 기준으로 약 3.5dB 개선, BLER 10^{-3} 기준으로 약 3dB 개선
- 제안 기법이 **SCL (L=4)**보다 모든 SNR 영역에서 좋음
→ BER 10^{-4} 기준으로 2.5dB 개선, BLER 10^{-3} 기준으로 약 1.2dB 개선



결론

- Conventional Polar SCL decoding algorithm 과 비교했을 때, 성능은 우수하지만 복잡도는 높은것으로 파악됨
 - 제안 수신기의 복잡도 대부분은 HGN decoder가 차지
 - 짧은 길이의 부호어에 보다 효과적으로 적용 가능,
성능 개선이 필요한 다양한 복호기에 제안 denoiser를 접목하여 **적은 복잡도의 추가로 성능을 크게 향상시킬 수 있음**
- Future work
 - BCH, LDPC 부호 등 다른 선형 부호에 적용하여 해당 부호의 conventional한 복호기법과 비교 가능
 - 복호기 복잡도 개선
 - 신경망 구조 단순화, 파라미터 수 줄이는 방안



참고문헌

- [1] Nachmani, E., Be'ery, Y., and Burshtein, D, "Learning to decode linear codes using deep learning," in Proc. Annu. Allerton Conf. Commun., Control, Comput, Sep. 2016, pp. 341–346.
- [2] Lugosch, L., and Gross, W. J. "Neural offset min-sum decoding," in Proc. IEEE Int. Symp. Inf. Theory (ISIT), Jun. 2017, pp. 1361–1365.
- [3] Nachmani, E., and Wolf, L. "Hyper-graph-network decoders for block codes," in Proc. Advances in Neural Inform. Proces. Systems (NIPS), 2019, pp. 2329–2339.
- [4] 한소영, 김정현, 송홍엽. "Residual learning denoiser를 적용한 Hyper-Graph-Network 복호기." 한국통신학회 학술대회논문집 2022.2 (2022): 44-45.
- [5] 한소영, 김정현, 송홍엽, "Denoising autoencoder를 이용한 새로운 구조의 채널 denoiser." 한국통신학회 학술대회논문집 2022.6
- [6] M. Hu, J. Li, and Y. Lv, "A comparative study of polar code decoding algorithms," in 2017 IEEE 3rd Information Technology and Mechatronics Engineering Conference (ITOEC), pp. 1221–1225, IEEE, 2017.
- [7] Sybis, M., Wesolowski, K., Venkatasubramanian, V., and Vukadinovic, V, "Channel coding for ultra-reliable low-latency communication in 5G systems.", in 2016 IEEE 84th vehicular technology conference, 2016, pp. 1-5.
- [8] Zhu, H., Cao, Z., Zhao, Y., and Li, D, "Learning to denoise and decode: A novel residual neural network decoder for polar codes," IEEE Trans. Veh. Technol., vol. 69, no. 8, pp. 8725–8738, Aug. 2020.