

오토인코더 기반 잡음 제거 모듈이 결합된 HGN 복호기와 conventional polar SCL 복호기 간의 성능 및 복잡도 비교

한소영, 김정현*, 송홍엽

연세대학교, 세종대학교*

{sy.han, hysong}@yonsei.ac.kr, j.kim@sejong.ac.kr

Comparison of complexity between HGN decoder with autoencoder denoiser and conventional polar SCL decoder

Soyoung Han, Junghyun Kim*, Hong-Yeop Song

Yonsei Univ., Sejong Univ.*

요약

본 논문은 [5]에서 제안한 오토인코더 기반 잡음 제거 모듈이 결합된 HGN 복호기와 conventional polar SCL 복호기 간의 성능과 복잡도를 비교, 분석한다. 그 결과, 제안 수신기가 더 좋은 복호 성능을 가졌지만 복잡도는 높은 것으로 파악되었다. 하지만, 잡음 제거 모듈의 복잡도는 수신기 복잡도에서 작은 비중을 차지하기에, 비교적 짧은 길이의 부호나 복잡도가 낮지만 성능 개선이 필요한 복호기 등에 본 모듈의 사용을 제안한다.

I. 서론

최근 딥러닝 기술의 급속한 발전으로 오류정정부호의 복호에도 다양하게 사용되고 있다. Tanner graph의 node를 뉴런으로 대체하여 신뢰전파 알고리즘을 발전시킨 neural belief propagation(NBP) 복호 기법[1]을 시작으로 neural offset min-sum 복호 기법[2], HGN(hyper-graph-network) 복호 기법[3] 등 딥러닝을 사용한 여러 복호 기법들이 최근에 제안되었다. 이러한 기법들은 vanilla belief propagation(BP) 복호기를 능가하는 성능을 보여주었다. 하지만 충분한 성능을 얻기 위하여 학습 시간이 매우 오래 걸린다는 한계가 존재한다. 이러한 한계를 극복하기 위하여 [4]에서 기존 HGN 복호기에 잔차 연결이 있는 CNN 잡음 제거 모듈을 접목한 수신기를 제안했으며, [5]에서는 오토인코더 기반 잡음 제거 모듈을 갖는 수신기를 제안하여 더 발전된 성능을 보였다.

본 논문에서는 [5]에서 제안한 수신기와 conventional한 polar 복호 기법 중 가장 좋은 성능을 보이는 SCL(successive cancellation list) 복호 기법 [6]의 polar 부호 복호 성능을 비교한다. 추가적으로 수신기 복잡도도 비교함으로써 짧은 길이의 부호에 해당 기술 적용을 제안한다.

II. 본론

본 논문에서는 polar 부호의 복호에 사용되는 SCL 기법과 제안한 잡음 제거 오토인코더를 접목한 수신기의 복잡도를 비교하고 이를 분석한다. SCL 복호기의 복잡도는 [7]에서 알려진 바와 같이 $O(LN \log_2 N)$ 의 시간 복잡도를 갖는다. 여기서 L 은 list의 개수이고 N 은 부호어의 길이이다. [5]에서 제안한 송수신기와 잡음 제거 모듈의 구조는 각각 그림 1, 2와 같다. 수신기 부분은 잡음 제거 모듈과 복호기로 구성되어 있어, 각각의 복잡도를 합친 것이 전체 수신기의 복잡도가 된다. 잡음 제거 모듈의 학습 복잡도는 $O(4NC_1C_2)$ 와 같이 계산된다. C_k 는 잡음 제거 모듈 구조

에서 k 번째 레이어의 채널 사이즈이다. 제안 구조에서는 C_1 과 C_2 를 각




그림 1. 수신기 학습 모델 구조 [5]




그림 2. 오토인코더 기반 잡음 제거 모듈 구조 [5]

각 15와 7로 설정하였다.

HGN 복호기의 학습 복잡도는 계산 결과 $O(l_{\max} N^3 d_v^3)$ 의 연산 복잡도를 갖는다. 여기서 $l_{\max}$ 는 HGN 복호기의 NN 구조 상의 레이어 수의 절반에 해당되며, BP 복호에서의 반복 횟수와 같다. 제안 구조에서는 이를 5로 설정했다. d_v 는 패리티 검사 행렬 H 에서의 변수 노드의 차수로 H 의 각 열에서의 1의 개수를 뜻한다. 따라서 전체 수신기의 학습에 필요한 연산 복잡도는 $O(l_{\max} N^3 d_v^3 + 4NC_1C_2)$ 로 계산된다.

계산 결과, 기존 SCL 복호 기법의 복잡도 대비 제안 수신기의 복잡도가 큰 것으로 나타났다. 특히, 전체 복잡도의 대부분은 HGN 복호기가 차지한다. 이는 부호 길이와 변수 노드의 차수에 크게 의존하며, 그 수는 부호 길이가 훨씬 크다. 따라서 부호 길이가 길어질수록 수신기의 복잡도가 크게 증가하여 원하는 성능을 내기까지 학습시간이 더 오래 걸릴 수 있다. 그림 3, 4는 Polar (64, 48)에서 제안 수신기의 성능을 비교한 그래프이다. 본 논문에서는 잡음 제거 모듈이 없는 HGN 복호기 및 리스트 크기 4를 갖는 SCL 복호기와 제안 수신기간의 비트 오류율 및 블록 오류율 성능을 비교하였다. 제안 수신기 학습에서 옵티마이저는 adam, 학습률은 10^{-5} 을 적용하였고, 배치 사이즈는 500으로 하여 에포크 5에서 최종 성능을 뽑았다.




그림 3. Polar (64,48)의 비트 오류율 성능 비교




그림 4. Polar (64,48)의 블록 오류율 성능 비교

실험 결과 제안 수신 기법이 두 비교군 사이에서 전반적으로 우수한 성능을 보였다. SCL 복호기법과 비교했을 때 BER 10^{-4} 을 기준으로 $2.5dB$ 개선되었고, BLER 10^{-3} 기준으로는 $1.5dB$ 가량 성능 개선이 있었다. 본 테스트 성능은 에포크 5에서 뽑았지만 에포크 수를 늘려 학습을 더 진행하면 더욱 우수한 성능을 낼 수 있다. 에포크 수를 10으로 정해 추가적으로 학습을 진행한 결과 BER 10^{-5} 를 기준으로 $1dB$, BLER 10^{-4} 를 기준으로 약 $1.2dB$ 가량 성능 개선을 보였다.

오토인코더 기반 잡음 제거 모듈을 추가함으로써 단 1%의 에포크 수만으로 기존 HGN 복호기의 성능을 크게 끌어올렸다. BER 10^{-4} 기준으로 $3.5dB$, BLER 10^{-3} 기준으로 $3dB$ 정도의 꽤 큰 성능 개선을 보였으며, [5]의 결과를 통해 [8]에서 제안된 같은 복잡도의 잡음 제거 모듈과 비교했을 때도 본 모듈이 월등함을 볼 수 있다. 본 논문은 제안한 잡음 제거 모듈을 사용함으로써 수신기의 복잡도 면에서 약간 손해를 보더라도 전체

수신기의 복호 성능을 크게 향상시킬 수 있음을 보였다.

III. 결론

본 논문에서는 conventional SCL 복호기와 오토인코더 기반 잡음 제거 모듈을 접목한 HGN 복호기의 성능과 복잡도를 비교, 분석하였다. Big O 함수로 연산 복잡도를 도출한 결과, SCL 복호기 대비 제안 수신기가 더 큰 복잡도를 가짐을 확인했다. 하지만 제안 수신기의 성능은 conventional SCL 복호 성능보다 월등함을 확인하였다. 따라서 본 잡음 제거 모듈을 비교적 복호시간이 적게 걸리는 짧은 길이의 부호어에 보다 효과적으로 적용할 수 있으며, 성능 개선이 필요한 다양한 복호기에 접목하여 적은 복잡도 추가로 성능을 크게 향상시킬 수 있다.

본 수신기는 polar 부호의 복호에만 제한되지 않고 BCH 부호, LDPC 부호 등 모든 선형 부호에도 사용될 수 있다. 향후 본 논문에서 다루지 않은 다른 부호에 적용하여 해당 부호의 conventional한 복호기법과도 비교하여 제안 모델의 성능을 검증할 수 있다. 추가적으로 본 수신기의 개선을 위하여 신경망 구조를 단순화하거나 파라미터 수를 줄이는 등의 방안으로 HGN 복호기의 복잡도를 개선할 수 있다.

ACKNOWLEDGMENT

이 (성과)는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No.2020R1A2C2011969).

참 고 문 헌

- [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.