

학습 데이터 구성 전략에 따른 신경망 기반 복호기의 성능 개선

나혜연¹, 박지연¹, *박호성¹, 곽희열², 안석기³

전남대학교¹, 울산대학교², 한국전자통신연구원³

nhy0052@naver.com¹, wldus8677@gmail.com¹, *hpark1@jnu.ac.kr¹, hykwak@ulsan.ac.kr², seokki.ahn@etri.re.kr³

Optimizing Neural Decoder with Learning Data Configuration Strategies

Hyeyeon Na¹, Jiyeon Park¹, *Hosung Park¹, Hee-Youl Kwak², Seok-Ki Ahn³

Chonnam National University¹, University of Ulsan², ETRI³

요약

본 논문은 Neural Min Sum 네트워크를 사용하여 신경망 기반 복호기의 성능을 향상시키는 방법을 연구하며, 특히 학습 데이터 세트 구성 방법 및 학습 방법이 복호기의 성능에 미치는 영향을 분석한다. 이를 위해 다양한 방법으로 학습 데이터 세트를 구성하였으며, 두 가지의 초기값 설정에 대해 신경망을 훈련시킨 후 블록 오류율(block error rate, BLER)을 측정함으로써 결과를 비교 분석하였다.

I. 서론

딥러닝 및 인공 신경망의 지속적인 발전은 현대 통신 네트워크의 최적화와 효율성 향상에 광범위하게 기여하고 있으며, 이러한 기술은 특히 높은 오류 정정 능력을 필요로 하는 통신 시스템에서 중요한 역할을 하고 있다. 이에 따라 5G NR 시스템에서 사용되는 저밀도 패리티 체크(low density parity check, LDPC) 부호의 복호 알고리즘에 신경망 기술을 적용한 Neural Min Sum(NMS) 복호 알고리즘이 주목받고 있다.

학습 데이터셋의 구성은 이러한 신경망 기반 복호 네트워크의 성능에 직접적인 영향을 미치는 결정적 요소이다. 일반적으로, 학습 데이터셋은 all-zero 코드워드에 특정 dB 수준의 노이즈를 추가함으로써 생성되는데, 이 dB 수준은 학습 데이터의 질과 네트워크가 학습할 수 있는 노이즈의 다양성 및 복잡성을 결정한다. 따라서, 이는 모델의 정확도와 일반화 능력에 직접적인 영향을 끼친다.

본 논문은 NMS 복호기의 효율적 학습을 통한 성능 향상을 목표로, 다양한 학습 데이터셋 구성 방식과 학습 방법이 복호기의 성능에 미치는 영향을 체계적으로 비교 분석하며 이를 통해 최적의 학습 전략을 제안한다.

II. 본론

1. Neural MS 복호기

Neural MS 복호는 belief propagation 복호 알고리즘에 비해 낮은 복잡도로 유사한 성능을 달성할 수 있어 효과적인 대안으로 사용되고 있다. 각 반복 l 에서 체크 노드(check node, CN)와 가변 노드(variable node, VN)는 다음의 식에 따라 메시지를 생성하고 서로 주고받으며 복호를 수행한다. 복호는 최대 반복 횟수에 도달하거나 모든 패리티 검사를 만족할 때 종료된다.

$$m_{v \rightarrow c}^{(i)} = m_v + \sum_{c' \in N(v) \setminus c} m_{c' \rightarrow v}^{(i)}$$

수식 1. 가변 노드 업데이트 식

$$m_{c \rightarrow v}^{(i)} = \alpha \times \left(\prod_{v' \in N(c) \setminus v} \text{sgn}(m_{v' \rightarrow c}^{(i)}) \right) \times \min_{v' \in N(c) \setminus v} |m_{v' \rightarrow c}^{(i)}|$$

수식 2. 체크 노드 업데이트 식

여기서 $m_{c \rightarrow v}^{(i)}$, $m_{v \rightarrow c}^{(i)}$ 는 각각 CN c 가 VN v 로 보내는 메시지와 VN v 가 CN c 로 보내는 메시지를 나타내며 x 에 이웃한 노드들은 $N(x)$ 로 표현된다. $m_{c \rightarrow v}^{(i)}$ 계산 식에서 정규화 요소 α 는 Neural MS 네트워크의 학습 매개변수(가중치)로, CN이 내보내는 메시지의 크기를 적절하게 조정하여 복호기의 성능을 개선하는 역할을 한다.

본 연구에서 사용하는 신경망 네트워크 구조는 [1]에 제시된 구조를 기반으로 한다. 이 구조는 부호길이와 부호율에 맞춰 최적화된 학습을 통해 프로토 그래프 기반 LDPC 부호화에 효과적이다. 또한 한 번 학습된 레이어의 가중치는 고정되어 다음 반복에 재사용되며, 각 반복에서는 오직 마지막 레이어의 가중치만을 업데이트하는 반복됨 탐욕적 학습 방법이 특징이다. 또한 하나의 반복에서 모든 노드가 하나의 가중치를 공유하여 사용하는 공간적 가중치 공유 방식(spatial weight sharing)[2]을 사용한다.

2. 학습 데이터 세트 구성

일반적으로 Neural MS 네트워크의 학습 데이터셋 구성은 다양한 dB 수준에서 생성된 데이터를 혼합하여 사용한다. 이 접근법은 여러 dB 수준에서 생성된 데이터를 섞어서 각 학습 batch를 구성하고, 각 반복마다 이를 활용하여 네트워크가 다양한 노이즈 환경에서의 데이터를 학습할 수 있게 함으로써 모델의 일반화 능력을 향상시킨다. 반면 일부 연구에서는 각 학습 반복에 단일 dB 수준에서 생성된 데이터만을 사용하는데, 이 방법은 특정 노이즈 수준에 대한 모델의 성능 최적화에 중점을 두고 있다. 본 연구는 후자의 방법을 활용하여 초반 반복에는 낮은 dB에서, 후반 반복에는 높은 dB에서 생성된 데이터를 학습 데이터로 사용하는 방식을 제안하며, 다른 데이터셋 구성 방식과의 성능 비교 결과를 제시한다.

학습 데이터셋을 아래와 같이 세 가지 방식으로 구성하여 각각에 대해 학습을 수행하였다. Case 1의 경우에는 일반적으로 사용되는 방법으로, 각 dB 수준에서 10개의 데이터를 생성하여 batch를 구성하고 batch 내에서 데이터 순서를 무작위로 섞어주었다. Case 2는 초반 반복에서는 낮은 노이즈 수준에서 학습하며 후반 반복에서는 높은 노이즈 수준에서 학습을 하는 방법이고, Case 3은 이와 반대되는 접근법이다. 이때 본 연구에서는 정규화 요소(α)값이 0.75인 weighted min-sum(WMS) 알고리즘의

BLER 그래프에서 waterfall 영역에 해당하는 3dB와 error-floor 영역의 시작점에 해당하는 4dB를 두 가지 학습 포인트로 설정하였다.

Case 1	3dB, 4dB에서 생성된 데이터를 혼합하여 batch 구성
Case 2	초반 반복(1~10): 3dB에서 생성된 데이터로 batch 구성 후반 반복(11~20): 4dB에서 생성된 데이터로 batch 구성
Case 3	초반 반복(1~10): 4dB에서 생성된 데이터로 batch 구성 후반 반복(11~20): 3dB에서 생성된 데이터로 batch 구성

3. 실험

본 연구에서는 길이 576, 부호율이 3/4인 WiMAX QC-LDPC 부호를 사용하였으며, BPSK 변조된 신호를 AWGN 채널 환경에서 복호하고 블록 오류율(BLER) 성능을 측정 후 비교 분석하였다. Q4.1에 의해 정의되는 5-비트 균일 양자화 방식[3]이 복호 과정의 모든 메시지에 적용되었고, 최대 LLR 값은 20으로 설정되었다. 이러한 양자화 방식은 정수 부분에 4비트, 소수 부분에 1비트를 사용하는 방식으로, 5-비트 정밀도의 균일 양자화 방식들 중에서 최상의 결과를 보여준다.

학습을 위해 초기값 1, 최대 반복 횟수 20, batch 크기 20, 각 반복 당 batch 개수 30000, epoch 1, 학습률 0.001을 적용하였고, 이진 크로스 엔트로피 손실 함수와 Adam 최적화 기법을 사용하였다. 학습 과정에서는 각 반복마다 새롭게 생성된 데이터셋을 사용하였다.

각 학습 방식에 따른 BLER 성능 결과는 그림1에 제시되어 있다. Case 1과 달리 case 2와 case 3에서는 WMS 알고리즘의 성능이 크게 개선되었으며, 특히 case 2의 성능이 가장 우수함을 확인할 수 있다. 이는 단일 dB 수준에서 집중적으로 학습하는 방식이 여러 dB의 데이터를 혼합하여 학습하는 방식보다 더 효과적임을 시사한다. 또한 낮은 SNR의 경우 적은 반복 횟수로도 복호를 성공할 수 있지만, 높은 SNR의 경우에는 더 많은 반복 횟수가 필요하다. 이 경우에 네트워크의 후반 반복 부분이 높은 SNR에 최적화되어 학습되었다면, 이러한 학습 데이터셋 설정이 더 유리하다고 해석할 수 있다.

각 경우에 대한 학습 결과 값의 분포는 그림2에 제시되어 있다. 일반적으로 4dB에서 학습할 때는 높은 값으로, 3dB에서 학습할 때는 상대적으로 낮은 값으로 학습되는 것을 확인할 수 있다. 이는 데이터셋 구성이 네트워크의 학습에 큰 영향을 미치는 것을 보여준다. 추가적으로 모든 경우에 대해 초기값을 1이 아니라 0과 1 사이의 랜덤값으로 설정한 후 학습하였고, 결과는 소수점 셋째 자리까지 동일하게 나타났다. 이때 양자화의 영향으로 인해 초기값에 상관없이 복호기의 성능이 동일함을 확인하였다.

III. 결론

이 연구는 NMS 기반의 복호기를 사용하여 학습 데이터셋의 구성 방법이 복호기 성능에 미치는 영향을 분석하였다. 연구 결과는 다양한 dB 수준의 데이터를 혼합한 일반적인 학습 방법보다, 각 반복에서 특정 dB 수준에 집중하여 학습하는 방식이 복호기의 성능을 더욱 향상시키는 것으로 나타났다. 특히 case 2의 접근 방식이 가장 우수한 성능을 보였으며, 이는 후반 반복에서 높은 SNR 수준의 데이터로 학습하는 것이 복호 성능 개선에 유리하다는 점을 시사한다. 본 연구에서는 특정한 두 SNR 포인트를 사용하여 실험을 진행하였는데, 향후 다양한 SNR 포인트를 사용하도록 확장함으로써 복호기의 성능을 더욱 개선할 수 있을 것으로 기대된다. 또한 이와 같이 학습 데이터셋의 구성을 최적화하는 접근법은 다양한 노이즈 환경에서 복호기 성능을 개선하기 위한 학습 전략을 개발하는 데 기여할 것으로 예상되며, 이를 통해 통신 시스템의 효율성과 신뢰성을 높일 수 있을 것으로 기대된다.

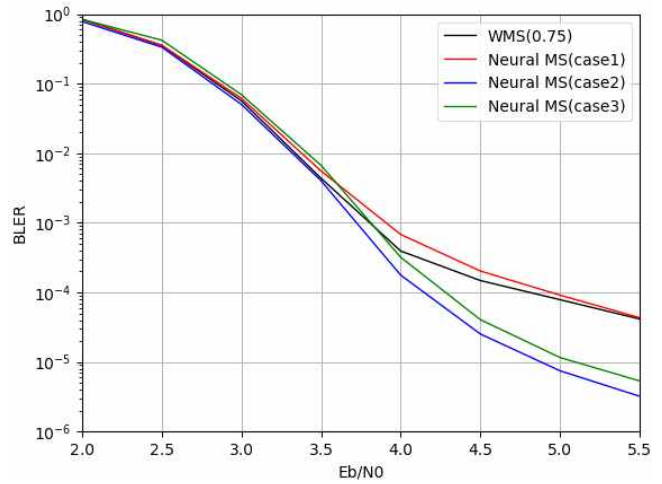


그림 1. 학습 데이터셋 구성 방식에 따른 블록 오류율

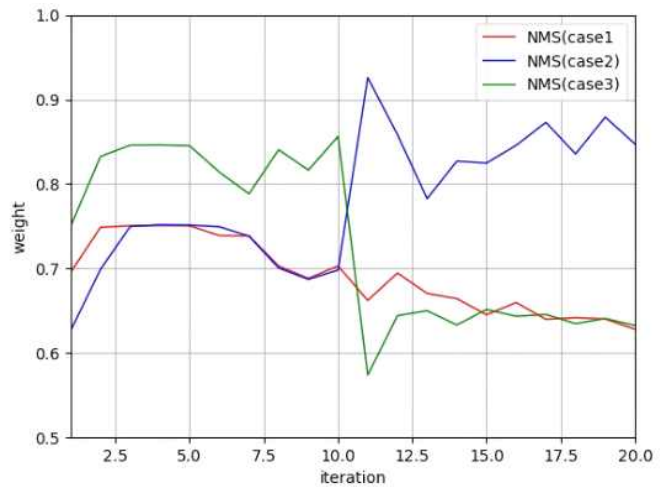


그림 2. 학습 데이터셋 구성 방식의 학습 결과 분포

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 지역지능화혁신인재양성사업(IITP-2024-00156287, 40%)과 (No. 2021001016004, 6G/B5G xURLLC를 위한 유연한 신뢰도의 채널코딩)의 연구이자, 더불어 한국전자통신연구원 내부연구개발사업 통신미디어 표준특허 경쟁력 강화 기술 개발(23YC1100)의 지원과 교육부와 한국연구재단의 재원으로 지원을 받아 수행된 첨단분야 혁신융합대학사업(차세대통신)의 연구 결과임.

참고 문헌

- [1] Jincheng Dai, Kailin Tan, Zhongwei Si, Kai Niu, Mingzhe Chen, H.Vincent Poor, Shunguang Cui, "Learning to Decode Protograph LDPC Codes," IEEE journal on Selected Areas in Communications, vol.39, pp. 1983-1999
- [2] M. Lian, F. Carpi, C. Häger and H. D. Pfister, "Learned Belief-Propagation Decoding with Simple Scaling and SNR Adaptation," 2019 IEEE International Symposium on Information Theory (ISIT), Paris, France, 2019, pp. 161-165
- [3] S.Kang, J.Moon, J.Ha and J.shin, "Breaking the Trapping Sets in LDPC Codes: Check Node Removal and Collaborative Decoding," in IEEE Transactions on Communications, vol.62, no.1, pp.1-14