

고속 수렴성을 갖는 딥 러닝 기반 채널 부호 복호기

한석주, 하정석

한국과학기술원

enfgui@kaist.ac.kr, jsha@kaist.edu

Deep Neural Decoder with Fast Convergence

Han Seokju, Ha Jeongseok

Korea Advanced Institute of Science and Technology

요약

본 논문은 향상된 수렴 속도를 갖는 딥 러닝 기반 채널 부호 복호기를 제안한다. 신뢰 전파 알고리즘 기반의 딥 러닝 채널 부호 복호기는 노드 사이의 메시지 전파 간 가중치의 할당을 통해 기존 신뢰 전파 알고리즘의 복호 성능을 향상시킨다. 딥 러닝 기반 복호기는 학습 과정에서 중간 출력 값을 갖는 채널 복호기의 특성을 반영한 손실함수의 설계를 통해 그 성능을 더 향상시킬 수 있으며, 본 연구에서는 채널 복호기의 특성을 반영한 그리디 알고리즘 기반의 손실 함수를 정의함으로써, 딥 러닝 기반 채널 부호 복호기의 수렴 속도 향상을 통한 복잡도 및 오류 정정 성능을 개선하는 방법을 제안한다. 실험을 통해 제안하는 알고리즘이 복잡도 및 오류 정정 성능을 향상시킴을 확인하였다.

I. 서론

최근 기계학습 기술은 연산 속도, 메모리의 발달 및 데이터의 크기 증가에 따라 급속을 받고 있다. 특히 딥 러닝 (deep learning)은 다계층의 신경망 구조를 활용하여 주어진 데이터로부터 학습 과정을 통해 사물 인식, 자연어 처리 등 다양한 분야에서 뛰어난 성능을 보이고 있다.

채널 부호는 정보의 부호화를 통해 정보의 성공적인 전달을 목표로 한다. 잘 알려진 채널 부호 중 하나인 저밀도 패리티 검사 (low-density parity-check, LDPC) 부호는 신뢰 전파 (belief propagation, BP) 알고리즘을 기반으로 채널 용량에 근접한 높은 오류 정정 성능을 갖는다. 하지만 이는 긴 길이의 부호에 한정되어, 짧은 길이에서 BCH 부호 [1]와 같은 고밀도 패리티 검사 (high-density parity-check, HDPC) 행렬을 갖는 대수적 부호(algebraic code)의 복호기가 연구되고 있다. 다수의 사이클로 인해 신뢰 전파 알고리즘의 경우, ML (maximum likelihood) 복호 성능에 비해 성능이 크게 떨어지는 문제가 있어 최근 딥 러닝을 통해 이러한 문제를 해결하기 위한 노력들이 연구 중이다. 대표적으로 [2]에서는 신뢰 전파 복호기를 심층 신경망으로 구성하고, 메시지 전파에 가중치를 부여하여 신뢰 전파 알고리즘의 복호 성능을 향상시켰으나 아직 오류 정정 성능과 복잡도 사이의 문제가 남아있는 상황이다. 현재까지의 신경망 기반 신뢰 전파 복호기는 복호기의 구조 이외에 손실 함수의 설정 등 학습 과정이 채널 부호의 복호 방식에 최적화되어 있지 않다. 본 논문에서는 기존 심층 복호기의 학습 방법을 개선하여, 중간 출력 값을 갖는 채널 복호기의 특성을 반영한 그리디 알고리즘 (greedy algorithm) 기반의 새로운 손실함수의 정의를 통해 심층 복호기의 수렴 속도 및 오류 정정 성능을 향상시키는 방법을 제안한다.

II. 신경망 기반 신뢰 전파 복호기

본 논문에서는 일반적인 선형 부호의 신뢰 전파 복호 알고리즘을 기반으로 딥 러닝 기반 복호기를 설계한다. 신뢰 전파 복호 알고리즘은 선형 부호를 테너 그래프로 표현하여 변수 노드 (variable node, VN)와 검사 노드 (check node, CN) 간 신뢰도 메시지를 전파하며 복호가 진행된다. 신뢰 전파 복호기의 입력은 채널로부터 받은 입력을 로그 우도비(log likelihood

ratio, LLR)로 변환하여 사용한다.

$$l_v = \log \frac{\Pr(c_v = 1|y_v)}{\Pr(c_v = 0|y_v)} \quad (1)$$

식 1에서 v 는 비트의 위치, y_v 는 채널로부터 받은 입력, c_v 는 실제 부호 값을 나타낸다.

신뢰 복호기의 복호 과정은 반복적인 메시지 전파로 진행된다. 본 논문에서는 메시지 전파의 반복 횟수를 i 로 표기하며, 최대 반복 횟수를 I_{\max} 로 설정한다. 변수 노드에서 검사 노드로의 메시지 전파는 홀수 번째 반복 횟수에 진행되고 검사 노드에서 변수 노드로의 메시지 전파는 짝수 번째 반복 횟수에서 진행되며 각각 식 2와 3으로 계산된다.

$$x_{i,e=(v,c)} = l_v + \sum_{e'=(v,c'), c' \neq c} x_{i-1,e'} \quad (2)$$

$$x_{i,e=(v,c)} = 2 \tanh^{-1} \left(\prod_{e'=(v',c), v' \neq v} \tanh \left(\frac{x_{i-1,e'}}{2} \right) \right) \quad (3)$$

각 반복 횟수 이후의 복호결과, $o_{v,i}$ 는 연결된 검사 노드로부터의 메시지를 더해 식 4로 계산된다.

$$o_{v,i} = l_v + \sum_{e'=(v,c')} x_{i,e'} \quad (4)$$

신뢰전파 복호 알고리즘의 반복적인 메시지 전파 구조는 각 메시지 전파를 신경망 층으로 구성하여 이를 심층 신경망으로 표현할 수 있다. 기존 연구 [2]는 식 2, 3의 신뢰전파 복호기를 심층 신경망 구조로 확장하여, 각 메시지 전달에 가중치 $w_{i,e}$ 를 할당한 식 5, 6 같은 복호기의 성능을 향상시킨다. 활성 함수의 안정성을 위하여 가중치는 검사 노드에서 변수 노드로의 메시지에만 할당된다.

$$x_{i,e=(v,c)} = \tanh \left(\frac{1}{2} \left(l_v + \sum_{e'=(v,c'), c' \neq c} w_{i,e'} x_{i-1,e'} \right) \right) \quad (5)$$

$$x_{i,e=(v,c)} = 2 \tanh^{-1} \left(\prod_{e'=(v',c), v' \neq v} x_{i-1,e'} \right) \quad (6)$$

III. 고속 수렴을 위한 신경망 신뢰 전파 복호기

신경망 신뢰전파 복호기는 초기 은닉 층에서의 경사 사라짐 문제 (vanishing gradient problem, VGP)를 해결하기 위해, 식 7에서 정의된 중간층에서의 결과 값을 활용한 다중 손실 함수 $L(o, c)$ 를 사용한다.

$$L(o, c) = \frac{1}{N} \sum_{i=1,3}^{I_{\max}} L_i(o_i, c) \quad (7)$$

$$L_i(o_i, c) = \sum_{v=1}^N c_v \log(o_{v,i}) + (1 - c_v) \log(1 - o_{v,i}) \quad (8)$$

신뢰전파 복호기는 각 반복 횟수 이후 출력된 결과 값을 활용해 복호결과를 출력한다. 만일 중간층에서의 출력값, o_i 가 패리티 검사를 만족하면 이후 층에 대한 연산 없이 복호결과를 출력할 수 있다. 본 연구에서는 신뢰전파 복호기의 특성을 활용하여, 그리디 알고리즘 (Greedy algorithm)을 기반으로 빠른 수렴을 위해 신경망 신뢰전파 복호기의 손실 함수를 다음 식 9와 같이 재정의 한다.

$$L(o, c) = \frac{1}{N} \sum_{i=1,3}^{I_{\max}} \alpha^{(i-1)/2} L_i(o_i, c) \quad (9)$$

재정의 된 손실 함수에서는 반복 횟수에 따른 가중치 $0 < \alpha \leq 1$ 를 설정하여 낮은 반복 횟수의 출력 값에 대한 손실을 학습 과정에서 가중을 두어 반영한다. 기존 손실 함수는 후기 출력 값과 초기 출력 값에 동일한 비중으로 학습되면서 초반 은닉 층의 학습에 후반 출력 값이 크게 반영되게 된다. 다중 손실 값에 대한 학습은 초반 은닉 층으로 갈수록 최적화된 가중치 값에 대한 학습에 어려움을 겪게 되고, 이는 전체 반복 횟수 I_{\max} 가 클수록 큰 문제가 된다. 또한, 그리디한 관점에서 신뢰전파 복호기는 최대한 빠른 반복 횟수에서 올바른 결정 값을 출력하는 것이 복잡도에 있어서 중요한 문제로 다뤄진다. 본 연구에서 재정의 한 손실함수는 α 의 도입을 통해 각 은닉 층의 학습이 인접 출력 값의 신뢰도에 가중을 둔 학습이 진행하도록 한다. 이를 통해 각 은닉 층은 적은 반복 횟수 이후에 올바른 복호결과를 출력할 수 있도록 학습되며, 이는 신경망 신뢰전파 복호기의 수렴속도를 향상시킨다. 또한 그리디한 알고리즘을 통한 중간 은닉 층에서의 신뢰도 향상은 후반 은닉 층으로 더 높은 신뢰도의 메시지를 전파하여 최종적인 오류 정정 성능도 향상시킬 수 있다.

실험은 (63,45) BCH 부호를 사용한다. 그림 1은 $E_b/N_0 = 4\text{dB}$ 인 AWGN 채널에서, 제안하는 손실 함수를 사용한 신경망 기반 복호기의 α 값 ($\alpha = 1, 0.8, 0.5, 0.3, 0.1$)에 따른 각 반복 횟수 이후 복호 성능을 나타낸다. 그래프의 결과에 따르면 제안하는 알고리즘은 기존 다중 손실 함수 ($\alpha = 1$)를 사용했을 때에 비해, 초반 반복 횟수에서 더 낮은 비트 오류율을 달성한다. 더욱이, 그래프를 통해 초반 반복 횟수에서의 높은 신뢰도를 통해 제안하는 알고리즘이 후반 반복 횟수에서도 더 좋은 오류 정정 성능을 가짐을 확인할 수 있다.

그림 2는 제안하는 알고리즘의 상대적 복잡도, C_{Rel} 를 나타낸다. 상대적 복잡도는 기존 다중 손실 함수를 사용했을 때 필요한 평균 반복 횟수, I_{ml} 와 제안하는 알고리즘을 사용했을 때의 평균 반복 횟수, $I_{prop, \alpha}$ 의 비율 $C_{Rel, \alpha} = I_{prop, \alpha} / I_{ml}$ 로 계산하였다. 그래프의 결과에 따르면 제안하는 알고리즘은 α 값의 설정에 따라 최대 10% 이상의 수렴 속도 향상을 통한 복잡도 이득을 얻을 수 있음을 확인할 수 있다. 그림 1과 2를 통해 제안하는 알고리즘이 복잡도 및 오류 정정 성능에 있어서 기존 알고리즘의 성능을 향상시킬 수 있다.




그림 1 반복 횟수에 따른 (63,45) BCH 부호의 비트 오류율 (AWGN 채널, $E_b/N_0 = 4\text{dB}$)




그림 2 기존 다중 손실 함수에 대한 상대적 복잡도, C_{Rel}

IV. 결론

본 논문에서는 고속 수렴성을 갖는 딥 러닝 기반 복호기를 제안한다. 중간 출력값을 갖는 신뢰 전파 복호기의 특성을 활용하여, 그리디 알고리즘 기반의 새로운 손실함수를 정의하여 딥 러닝 복호기를 설계하였다. 실험을 통해 제안하는 알고리즘이 기존 딥 러닝 복호기의 복잡도 및 오류 정정 성능을 모두 개선함을 확인하여, 딥 러닝 기반 복호기의 실제적 적용에 기여할 것으로 기대된다.

ACKNOWLEDGMENT

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

참 고 문 헌

- [1] Bose, Raj Chandra, and Dwijendra K. Ray-Chaudhuri. "On a class of error correcting binary group codes." *Information and control* 3.1 (1960): 68-79.
- [2] Nachmani, Eliya, Yair Be'ery, and David Burshtein. "Learning to decode linear codes using deep learning." 2016 54th Annual Allerton Conference on Communication, Control, and Computing (Allerton). IEEE, 2016.