

MISO-NOMA 브로드캐스트 시스템에서 머신러닝을 활용한 복호 기술

강민정, 이정훈*

한국의외국어대학교 전자공학과

love_minmin926@hufs.ac.kr, *tantheta@hufs.ac.kr

Decoding technology using machine learning in the MISO-NOMA broadcast system

Min Jeong Kang, Jung Hoon Lee*

Department of Electronics Engineering Hankuk University of Foreign studies

요 약

5G 또는 MIMO 와 같은 차세대 무선 통신 시스템에서 높은 주파수 효율로 주목받는 기술 중 하나인 비직교 다중 접속 (nonorthogonal multiple access, NOMA) 기술은 복호 순서에 따라 성능이 달라져, 최적의 복호 순서를 찾는 것이 중요한 문제로 여겨진다. 본 논문에서는 multiple-input single-output (MISO) NOMA broadcast 시스템에서 각 사용자 간의 채널 상관성을 이용하여 최적의 복호 순서를 구하는 과정에 머신러닝을 활용한 복호 기술을 제안한다.

I. 서 론

머신러닝(machine learning)은 인공지능 기술의 핵심 기술 중 하나이며, 주로 정보통신분야를 포함한 다양한 분야에서 시스템의 복잡도를 낮추고 성능을 향상시키기 위한 기술로 사용되고 있다. 5G, multiple-input multiple-output(MIMO)와 같은 차세대 무선 통신 시스템에서는 기기간 다중 접속의 증가에 따른 높은 시스템 복잡도를 머신러닝을 활용하여 낮추는 연구가 이루어지고 있다.

비직교 다중 접속(nonorthogonal multiple access, NOMA) 기술은 송신단에서 주파수 효율을 향상시키기 위해 모든 사용자들의 송신신호가 중첩코딩(superposition coding, SC)된 형태로 송신신호를 형성하고 사용자들은 송신신호에서 자신의 신호를 얻기 위해 송신신호에서 자신보다 채널 이득이 낮은 사용자들의 신호를 먼저 복호하여 제거하는 과정을 통해 자신의 신호를 구하는 순차적 간섭 제거(successive interference cancellation, SIC)를 사용하는 기술이다. NOMA는 주파수 효율이 높아 사용자 수가 많은 5G 무선 통신 시스템에서 주목받는 기술 중 하나이지만 복호 순서에 따라 성능 편차가 크므로 주어진 NOMA 시스템에서 최적의 복호 순서를 찾는 것은 중요한 문제로 여겨진다.[1]

본 논문은 사용자 수와 동일한 수의 안테나를 갖는 하나의 송신단과 각각 하나의 안테나를 가지며 얻을 수 있는 최대 데이터 전송량이 제한된 사용자들이 존재하는 multiple-input single-output(MISO) NOMA broadcast 시스템에서 각 사용자 간의 채널 상관성을 이용하여 최적의 복호 순서를 구하는 과정에 머신러닝을 활용한 복호 기술을 제안한다. 제안하는 머신러닝 모델의 성능은 반복적으로 구한 최적의 복호 순서와 제안하는 머신러닝 모델을 이용하여 구한 복호 순서를 통해 얻을 수 있는 총 데이터 전송량을 비교를 통해 검증한다.

II. 본론

본론에서는 본 논문에서 고려하는 시스템 모델에 대한 설명과 제안하는 머신러닝 모델 구조 및 성능 검증에 대한 내용을 다룬다.

① 시스템 모델

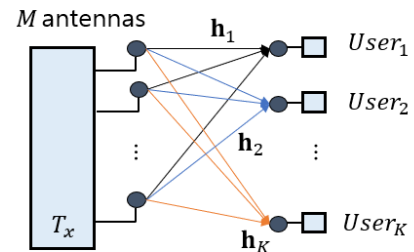


그림 1. 시스템 모델

그림 1은 본 논문에서 고려하는 시스템 모델이다. 총 K 명의 사용자가 존재하며 송신단은 M ($=K$)개의 안테나를 갖는다. 또한 MISO 시스템을 고려하므로, 송신단에서는 maximum ratio transmission (MRT)를 사용하여 사용자에게 송신신호를 전송한다고 가정한다. k 번째 사용자가 수신 받는 신호 y_k 는 다음과 같다.

$$y_k = \mathbf{h}_k^H \mathbf{x} + n_k. \quad (1)$$

$\mathbf{h}_k \in \mathbb{C}^{M \times 1}$ 는 k 번째 사용자의 채널을 의미하며, 각 사용자들의 채널 이득은 $\|\mathbf{h}_1\|^2 \geq \dots \geq \|\mathbf{h}_K\|^2$ 을 만족한다고 가정한다. $n_k \sim \mathcal{CN}(0, 1)$ 는 k 번째 사용자가 갖는 평균이 0 이고 분산이 1 인 additive white complex Gaussian noise 이다. 또한 $\mathbf{x} \in \mathbb{C}^{M \times 1}$ 는 송신신호를 의미하고 $\mathbf{x} = \sum_{k=1}^K \mathbf{w}_k x_k$ 로 구성된다. 송신신호 \mathbf{x} 를 구성하는 $\mathbf{w}_k \in \mathbb{C}^{M \times 1}$ 와 x_k 는 각각 k 번째 사용자의 빔포밍(beamforming) 벡터와 신호를 의미한다. 빔포밍 벡터 \mathbf{w}_k 는 $\mathbf{w}_k = \mathbf{h}_k / \|\mathbf{h}_k\|^2$ 을 통해서 구할 수 있으며, $\|\mathbf{w}_k\|^2 = 1$ 을 만족한다. k 번째 사용자의 데이터 전송량 R_k 는 다음과 같이 표현된다.[2][3]

$$R_k = \log_2 \left(1 + \frac{\|\mathbf{h}_k\|^2 p_k}{\sum_{i \neq k} |\mathbf{h}_k^H \mathbf{w}_i|^2 p_i + 1} \right). \quad (2)$$

p_k 는 k 번째 사용자의 전력을 의미하며, 사용자들이 최대 얻을 수 있는 최대 데이터 전송량이 γ 일 때, 전체 전력 P 에서 k 번째 사용자가 얻을 수 있는 최대 전력은 다음과 같이 계산된다.

$$p_k \leq (2^\gamma - 1) \left(\sum_{i \neq k} |\mathbf{h}_k^H \mathbf{w}_i|^2 p_i + 1 \right) / (\|\mathbf{h}_k\|^2 p_k). \quad (3)$$

또한, $p_1 + \dots + p_K = P$ 를 만족한다. 본 논문에서는 총 K 명의 유저가 존재할 때, 유저들 간의 채널 상관성을 이용하여 최대 총 데이터 전송량을 갖는 최적의 복호 순서를 찾으므로 가능한 총 복호 순서 S 는 $2^K - 1$ 개가 된다. 따라서, s 번째 복호 순서에서 q 번째 유저의 데이터 전송량은 다음과 같이 표현된다.

$$R_{(s,q)} = \log_2 \left(1 + \frac{\|\mathbf{h}_{(s,q)}\|^2 p_{(s,q)}}{\sum_{i \neq q} \frac{|\mathbf{h}_{(s,q)}^\dagger \mathbf{h}_{(s,i)}|^2}{\|\mathbf{h}_{(s,i)}\|^2} p_{(s,i)} + 1} \right). \quad (4)$$

식 (4)에 따르면, s 번째 복호 순서에서 q 번째 유저의 데이터 전송량을 구하기 위해서는 서로 다른 두 유저 간의 채널 이득과 각 유저들의 채널 이득이 필요하다. 따라서, 고려하는 채널 상관성을 나타내는 총 채널이득 G 는 $(k^2 + k)/2$ 개가 된다. 본 논문의 각 유저들은 임의의 데이터 전송량 γ 이하로 최대 데이터 전송량을 얻을 수 있으므로, s 번째 복호 순서에서 q 번째 유저가 최대 할당 받을 수 있는 전력은 다음과 같이 계산된다.

$$p_{(s,q)} \leq \frac{(2^\gamma - 1) \left(\sum_{i \neq q} \frac{|\mathbf{h}_{(s,q)}^\dagger \mathbf{h}_{(s,i)}|^2}{\|\mathbf{h}_{(s,i)}\|^2} p_{(s,i)} + 1 \right)}{\|\mathbf{h}_{(s,q)}\|^2 p_{(s,q)}}. \quad (5)$$

s 번째 복호 순서에서 구할 수 있는 유저들의 총 데이터 전송량과 유저들의 전력 합을 각각 $R_{(s)}$ 과 $P_{(s)}$ 라고 할 때, 유저들의 전력 합은 $P_{(s)} \leq P$ 가 된다. 따라서, 본 논문에서 구하고자 하는 최대 총 데이터 전송량을 갖는 최적의 복호 순서는 다음과 같다.

$$\underset{1 \leq s \leq S}{\text{maximize}} R_{(s)}. \quad (6)$$

② 제안하는 머신러닝 모델

본 논문에서 제안하는 머신러닝 모델은 심층 신경망 (deep neural network, DNN) 구조이며, K 명의 유저가 존재할 때 signal to noise(SNR)과 고려하는 채널 상관성을 나타내는 총 채널이득 G 에 따라 총 복호 순서 S 에서 최적의 복호 순서를 구하는 과정에 응용된다. 따라서, 입력노드와 출력노드는 각각 $G + 1$ 개와 S 개로 구성되며, L 개의 은닉층과 N 개의 은닉노드를 갖는다. DNN 구조인 머신러닝 모델이므로, gradient 의 값이 0 이 되는 현상을 방지하기 위하여 은닉노드의 활성화함수로 rectified linear unit(ReLU) 함수를 사용한다. 또한, softmax 함수를 출력노드의 활성화함수로 사용하여 S 개의 복호 순서 중 가장 높은 출력 데이터를 갖는 복호 순서를 최적의 복호 순서로 정하였다. 손실 함수 (loss function) 은 교차 엔트로피 함수를 사용하였고 초기 학습률을 0.001 로 설정한 adaptive momentum(adam) 최적화 알고리즘을 사용하였다. 손실 값이 일정할 경우, 학습을 조기멈춤하여 과적합을 방지하여 정확도를 향상시켰다.

③ 성능평가

본 논문에서는 총 5 명의 유저가 존재하고 각 유저들이 최대로 얻을 수 있는 임의의 데이터 전송량 γ 이 1 로 고정된 시스템에서 제안하는 머신러닝 모델의 성능을 반복적으로 구한 최적의 복호 순서와 머신러닝 모델을 이용하여 구한 최적의 복호 순서로부터 얻는 총 데이터 전송량을 비교하여 검증하였다. 그림 2 는 반복적으로

구한 최적의 복호 순서로부터 얻는 총 데이터 전송량으로 머신러닝 모델을 이용하여 구한 최적의 복호 순서로 얻는 총 데이터 전송량을 정규화한 결과이다.

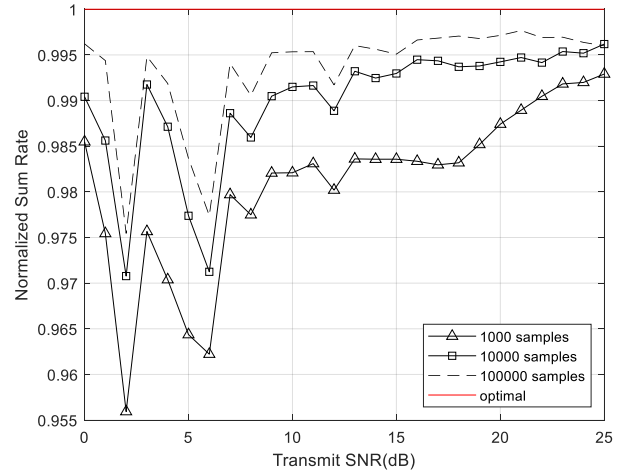


그림 2. 정규화 한 총 데이터 전송량

III. 결론

본 논문에서는 NOMA MISO broadcast 시스템에서 유저들이 최대로 얻을 수 있는 최대 데이터 전송량이 제한되어 있을 때, 유저들 간의 채널 상관성을 고려하여 최대 데이터 전송량을 갖는 최적의 복호 순서를 구하는 과정에 복잡도를 낮추기 위해 머신러닝을 활용한 복호 기술을 제안하였다. 최종적으로 반복적으로 구한 최적의 복호 순서로 얻은 총 데이터 전송량과 제안하는 머신러닝의 모델로 구한 최적의 복호 순서로 얻은 총 데이터 전송량을 비교하여 성능을 검증하였으며, 높은 유사도를 갖는다는 것을 확인하였다.

ACKNOWLEDGMENT

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT) (No. NRF-2021R1H1A1010858)

참고 문헌

- [1] M. K. Hasan, M. Shahjalal, M. M. Alam, M. F. Ahmed, Y. M. Jang, "The Role of Deep Learning in NOMA for 5G and Beyond Communications," In Proceedings of the Conference on Artificial Intelligence in Information and Communications (ICAIC), Fukuoka, Japan, pp. 19-21, Feb. 2020
- [2] H. Al-Obiedollah, K. Cumanan, J. Thiyagalingam, A. G. Burr, Z. Ding, and O. A. Dobre, "Energy efficiency fairness beamforming design for MISO NOMA systems," in Proc. IEEE Wireless Communication Networking Conference(WCNC), Jul. 2019, pp. 1-7
- [3] M. Zeng, A. Yadav, O. A. Dobre, G. I. Tsiropoulos, and H. V. Poor, "On the sum rate of MIMO-NOMA and MIMO-OMA systems," IEEE Wireless Communication Letter, vol. 6, no. 4, pp. 534-537, Aug. 2017