

MISO BC 채널에서 기계학습 기반 비직교 다중 접속 구현

강민정*, 이정훈^o

Implementation of NOMA with Machine Learning in MISO Broadcast Channels

Min Jeong Kang*, Jung Hoon Lee^o

요약

본 논문에서는 MISO(multiple-input single-output) 브로드캐스트 채널에서 기계학습에 기반한 비직교 다중 접속 기법을 제안한다. 비직교 다중 접속 기법의 경우 수신단에서 순차적 간섭 제거(successive interference cancellation, SIC)를 수행하는데, 이때 최적의 복호 순서를 찾아야 한다. 다중 안테나를 가진 송신단의 경우 단일 안테나와 달리 빔포밍과 각 채널의 상관도에 따라 각 수신단에서 수신한 유저 신호들의 세기 순서가 달라지므로 최적의 복호 순서를 찾기 어렵다. 특히 다수의 유저가 존재할 경우 계산의 복잡도가 높아지므로 최적의 복호 순서를 구하기 쉽지 않다. 본 논문은 유저들이 제공받는 데이터 전송률이 고정되고, 송신 빔포밍 기법이 최대비 송신(maximum ratio transmission, MRT)으로 고정될 때, 기계학습을 활용하여 최적의 복호 순서를 찾는다. 제안하는 기계학습 모델은 각 채널의 상관도와 송신 신호대 잡음비를 입력받아 최적의 복호 순서를 출력한다.

Key Words : Machine learning, non-orthogonal multiple access, multiple input single output broadcast channel, deep neural network, successive interference cancellation, decoding order

ABSTRACT

Non-orthogonal multiple access (NOMA) requires successive interference cancellation at the receiver, but the optimal decoding order is not easy to find especially when the transmitter has multiple antennas. In this paper, we use machine learning to implement NOMA in downlink multiple input single output broadcast channels when data rate for each user is fixed. Our machine learning model finds the optimal decoding order for given channel states.

1. 서론

최근 인공지능(artificial intelligence, AI)의 등장과

함께 과학 기술 전반에 걸쳐 새로운 기술들이 대거 등장했으며, 다양한 분야에 활용되고 있다. 인공지능에서 핵심적인 기술 중 하나인 기계학습(machine

※ This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT) (No. NRF-2021R1H1A1010858) and by Hankuk University of Foreign Studies Research Fund of 2021.

• First Author : Department of Electronics Engineering and Applied Communications Research Center, Hankuk University of Foreign Studies, love_minmin926@hufs.ac.kr, 학생회원

o Corresponding Author : Department of Electronics Engineering and Applied Communications Research Center, Hankuk University of Foreign Studies, tantheta@hufs.ac.kr, 정회원

논문번호 : 202202-026-A-RN, Received February 27, 2022; Revised April 8, 2022; Accepted April 12, 2022

learning, ML)은 주어진 데이터를 학습하고 적합한 모델을 형성하여 복잡한 문제의 해답을 찾거나 분류 및 판단하는 기술이다. 기계학습은 초기에는 큰 주목을 받지 못하였으나 최근 딥러닝(deep learning, DL)의 등장으로 크게 주목받고 있다¹¹⁾. 딥러닝은 컴퓨팅 기술의 발전과 함께 성장한 기술 중 하나이다. 기계학습과 전체적인 구조는 유사하지만 다수의 은닉층(hidden layer)을 가진다. 특정 분야에서는 사람보다 높은 판단 정확도를 보여 향후 많은 분야에서 더 널리 사용될 것으로 기대되고 있다¹²⁾.

5G/6G 시스템에서는 초고속, 초저지연, 초연결 등의 목표를 설정하여 더 복잡해진 문제들이 등장하였으며, 이를 해결하기 위한 한가지 방안으로 기계학습이 널리 고려되고 있다. 특히 기기 간 다중 연결 증가로 인한 기기 간 간섭 문제가 5G/6G 시스템에서 복잡도 높은 문제들로 여겨지고 있다. 이에 따라 5G/6G 시스템에서는 일반적으로 간섭 제어에 사용되던 기술 중 하나인 빔포밍(beamforming)을 고도화하는 연구가 활발히 이루어지고 있다¹³⁾. 특히 빔포밍 벡터는 고려해야 할 채널 수가 많고 시스템의 복잡도가 높을수록 계산이 복잡하여 최적인 빔포밍 벡터를 구하기 쉽지 않은데, 이러한 문제를 해결하기 위해 빔포밍 벡터를 낮은 복잡도로 구하는 과정에 대한 연구가 진행되고 있다. 송신단에서 얻고자 하는 조건을 활용하여 간섭적으로 빔포밍 벡터를 구하는 방법이 제안되었으며¹⁴⁾, semidefinite relaxation을 이용하여 전력 조건을 만족하는 빔포밍 벡터를 구하는 방법도 제안되었다¹⁵⁾. 또한 시스템 복잡도가 높을 경우 송신단과 수신단 사이의 채널 정보를 정확하게 알기 쉽지 않으므로 정규화된 채널 벡터를 사용하여 채널 정보 오류에 낮은 영향을 받는 빔포밍 벡터를 구하는 기법이 제안되었다¹⁶⁾. 그러나 시스템의 복잡도가 높을수록 원하는 알고리즘을 얻기 쉽지 않으므로 기계학습을 활용하여 빔포밍 벡터를 구하는 연구가 활발히 이루어졌다. 기계학습의 경우 학습 데이터를 기반으로 모델을 형성하므로 시스템의 복잡도에 큰 영향을 받지 않는다. 그러므로 임의의 전력 제한 조건으로 인해 복잡도가 높아진 시스템에서 기계학습을 활용하여 낮은 복잡도로 최적의 빔포밍 벡터를 찾는 기법이 제안되었다¹⁷⁾. 또한 기계학습 모델의 복잡도를 감소시키기 위해 모델 형성과정에 사용되는 학습 알고리즘의 복잡도를 감소시켜 더욱 빠르게 빔포밍 벡터를 구하는 기법이 제안되었다¹⁸⁾.

무선통신시스템의 발전과 함께 유저 수가 증가함에 따라, 주파수 효율을 향상시키기 위한 연구가 이루어

지고 있다. 그 중 비직교 다중 접속(non-orthogonal multiple access, NOMA)기술은 5G/6G 시스템에서 주목받는 기술 중 하나이다. NOMA는 각 유저들이 서로 다른 주파수 영역을 사용하는 직교 다중 접속(orthogonal multiple access, OMA)과 달리 각 유저들에게 서로 다른 전력을 할당하고 동일한 주파수 영역을 사용하는 기술이다. 그러므로 NOMA는 유저 간의 채널 상관도가 높은 시스템에서 OMA보다 더 좋은 성능을 갖는다¹⁹⁾. 이때 송신신호가 중첩코딩(superposition coding, SC)을 사용하여 구성되므로 수신단은 순차적 간섭 제거(successive interference cancellation, SIC)를 사용하여 송신신호에서 자신의 신호를 복호한다¹⁰⁾. SIC에서 주요한 요소 중 하나인 복호 순서는 일반적으로 송신단과 수신단이 단일 안테나인 NOMA 시스템에서는 채널 이득과 유사하지만 다중 안테나 NOMA 시스템에서는 유동적이므로 구하기 쉽지 않다.

NOMA에서는 주로 자원 할당, SIC 문제에 대한 연구가 활발히 진행되고 있다. 그러나 중첩코딩과 SIC로 인해 유저 수가 증가할수록 NOMA 시스템의 복잡도가 상승하여 각 문제들에 대한 최적의 값을 얻기 쉽지 않다. 이에 따라 복잡도 문제를 해결하기 위한 기술 중 하나로 기계학습이 고려되고 있다. 이때 주로 사용되는 기계학습 모델은 딥러닝 모델이며, 딥러닝을 활용하여 채널 상태가 빠르게 변화하고 시스템 구성이 복잡한 device to device(D2D) NOMA 시스템에서 제한된 전력 조건을 만족하고 유저 간의 전력 차가 존재하는 최적의 전력 할당 기법을 낮은 복잡도로 구하는 기법이 제안되었고¹¹⁾ NOMA 기반 이종 네트워크(heterogeneous network, HetNet) 시스템에서 딥러닝을 활용하여 효율적으로 사용자와 전력을 할당하는 기법이 제안되었다¹²⁾. 또한 다중 안테나 NOMA 시스템에서 총 데이터 전송률과 에너지 효율을 최대화하는 최적의 전력 할당 기법을 딥러닝을 활용하여 구하는 방법도 제안되었다¹³⁾. 이때 사용된 기계학습 모델은 기존 심층 신경망 모델에 몇 개의 convolution layer가 포함되어 있는 기계학습 모델이다. SIC는 채널 정보를 기반으로 동작하지만, 채널 정보를 완벽히 알기 쉽지 않으므로 딥러닝을 활용하여 완벽하지 않은 SIC에서도 빠르고 효율적으로 자원을 할당하는 기법이 제안되었다¹⁴⁾.

본 논문에서는 각 유저들이 얻어야 하는 SINR이 고정된 MISO NOMA 브로드캐스트 채널에서 기계학습을 활용하여 각 유저 간의 채널 상관관계를 토대로 가능한 모든 복호 순서 중 가장 큰 총 데이터 전송률

을 갖는 최적의 복호 순서를 찾는 방법을 제안한다. 이때, 제안하는 기계학습 모델은 낮은 복잡도로 최적의 복호 순서를 구하는 과정에 사용되며 심층 신경망 (deep neural network, DNN) 구조를 갖는다.

본 논문은 다음과 같이 구성된다. 2장에서는 K 명의 사용자가 있는 MISO NOMA 브로드캐스트 채널 시스템에 대해 구체적으로 설명하고 3장에서는 제안하는 기계학습 구조에 대해 자세히 설명한다. 4장에서는 제안하는 기계학습 모델을 활용하지 않고 반복적으로 구한 최적의 복호 순서와 제안하는 기계학습 모델을 활용하여 구한 최적의 복호 순서로 얻을 수 있는 총 데이터 전송률을 비교하여 제안하는 기계학습 모델의 성능을 평가한다. 마지막으로 5장에서는 전체 내용을 요약하고 마무리한다.

II. 시스템 모델

그림 1은 본 논문에서 고려하는 시스템 모델을 나타낸다. 총 M 개의 안테나를 갖는 하나의 송신단이 각각 한 개의 안테나를 가진 총 $K(\leq M)$ 명의 사용자 중 일부를 선택한 후 비직교 다중 접속 방식을 이용하여 서비스한다.

이 경우 k 번째 사용자에서의 수신 신호 y_k 는 다음과 같이 모델링 할 수 있다.

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

위 식에서 $\mathbf{h}_k \in C^{M \times 1}$ 는 k 번째 사용자의 채널을 나타내며 레일리 페이딩 채널(Rayleigh fading channel)을 가정한다. 한편, n_k 는 평균이 0이고 분산이 1인 k 번째 사용자의 백색 가우시안 노이즈를 나타낸다. 또한, \mathbf{x} 는 송신단이 K 명의 사용자들에게 송신하는 송신 신호이며, 다음과 같이 생성된다.

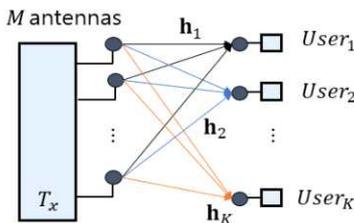


그림 1. 고려하는 시스템 모델
Fig. 1. System model

$$\mathbf{x} = \sum_{k=1}^K \mathbf{w}_k x_k. \quad (2)$$

위 식에서, x_k 는 k 번째 사용자의 신호를 나타내고, 각 사용자에게 할당된 전력은 p_k 로 나타낸다. (즉, $E[|x_k|^2] = p_k$ 이다.) 또한, $\mathbf{w}_k \in C^{M \times 1}$ 는 k 번째 사용자의 빔포밍 벡터를 나타낸다. 본 논문에서는 사용자들을 서비스하기 위해 송신단은 MRT 빔포밍 기법을 사용한다고 가정한다. 따라서, k 번째 사용자의 빔포밍 벡터 \mathbf{w}_k 는 $\mathbf{w}_k = \mathbf{h}_k / \|\mathbf{h}_k\|$ 로 주어지며 $\|\mathbf{w}_k\|^2 = 1$ 을 만족한다.

2.1 임의의 디코딩 순서를 위한 전력 할당 조건

본 논문에서는 각 사용자들이 송신 신호로부터 순차적 간섭 제거(successive interference cancellation, SIC) 후 자신의 신호를 복호한다. 전력 영역 NOMA에서는 채널 이득이 낮은 사용자에게 더 높은 전력을 할당하고, 결과적으로 각 사용자에서 자신의 신호보다 더 강한 신호(자신보다 채널이 더 안좋은 사용자의 신호)들을 순차적으로 복호한 후 수신신호에서 제거해나간다. 따라서 본 논문에서는 각 사용자들의 채널 이득 순서가 $\|\mathbf{h}_1\|^2 \geq \dots \geq \|\mathbf{h}_K\|^2$ 라고 가정하고, 각 사용자에서는 약한 채널을 가진 사용자의 신호부터 (강한 수신 신호부터) 순차적으로 복호하여 수신신호로부터 제거한다고 가정한다.

만약 복호 순서가 $K, \dots, 1$ 라고 가정할 때, k 번째 사용자의 경우 $K, \dots, k+1$ 번째 사용자의 간섭을 순차적으로 제거하고, $1, \dots, k-1$ 번째 사용자의 신호를 잡음으로 두고 자신의 신호를 복호한다. 그러므로 k 번째 사용자의 신호 대 간섭 잡음비 (signal-to-interference-plus-noise power ratio, SINR) $SINR_k$ 는 다음과 같이 표현된다.

$$SINR_k = \frac{p_k |\mathbf{h}_k^\dagger \mathbf{w}_k|^2}{\sum_{i=1}^{k-1} p_i |\mathbf{h}_k^\dagger \mathbf{w}_i|^2 + 1}. \quad (3)$$

여기서 p_k 는 k 번째 사용자의 전력을 의미한다. 송신단의 최대 전력을 P 라 할 때 다음 관계를 만족하여야 한다.

$$p_1 + \dots + p_K \leq P \quad (4)$$

한편, k 번째 유저의 데이터는 순차적 간접 제거를 위해, k 번째 유저 뿐만 아니라, $1, \dots, k-1$ 번째 유저들도 복호 할 수 있어야 한다. 유저 $j (< k)$ 가 유저 k 신호를 복호 할 때 얻을 수 있는 SINR인 $SINR_{(j,k)}$ 는 다음과 같이 주어진다.

$$SINR_{(j,k)} = \frac{p_k |h_j^\dagger w_k|^2}{\sum_{i=1}^{k-1} p_i |h_j^\dagger w_i|^2 + 1} \quad (5)$$

여기서 식 (3)은 $SINR_{(k,k)}$ 에 해당한다.

본 논문에서 송신단은 고정된 데이터 전송률 $\log_2(1 + \gamma)$ 로 유저들에게 서비스한다고 가정한다. 따라서 최대한 많은 유저들의 SINR이 동시에 γ 가 되도록 송신단이 전력을 할당하여야 하고, k 번째 유저에게 할당하는 전력 p_k 는 k 번째 유저 자신이 얻는 SINR을 γ 로 만들어주어야 할 뿐만 아니라, k 번째 유저의 데이터를 복호하는 모든 유저가 k 번째 유저로부터 얻을 수 있는 SINR을 γ 로 만들어주어야 한다.

식 (3)과 식 (5)로부터 $j (\leq k)$ 번째 유저가 k 번째 유저의 신호를 복호하기 위한 전력 $p_{(j,k)}$ 는 다음과 같이 계산된다.

$$p_{(j,k)} = \gamma \cdot \left(\frac{\sum_{i=1}^{k-1} p_i |h_j^\dagger w_i|^2 + 1}{|h_j^\dagger w_k|^2} \right) \quad (6)$$

따라서 k 번째 유저가 할당 받아야 하는 전력은 다음과 같다.

$$p_k \geq \max(p_{(1,k)}, \dots, p_{(k,k)}) \quad (7)$$

만약 전력 할당 이후 식 (4)를 만족하지 않는다면, 약한 채널부터 복호하는 복호 순서는 가능하지 않다.

2.2 풀고자 하는 문제

본 논문에서는 총 K 명의 유저가 존재할 때 가능한 모든 복호 순서 중 제한된 송신 전력으로 최대 총 데이터 전송률을 갖는 최적의 복호 순서를 구하고자 한다.

송신단이 다중 안테나를 사용할 경우 최적의 복호 순서는 채널에 따라 변화하고, 식 (5)에서 관찰할 수 있듯이 유저 간의 채널 상관관계에 따라 결정된다. 각

유저들의 언어야 하는 데이터 전송률이 $\log_2(1 + \gamma)$ 로 고정되어 있으므로, 서비스가 가능하도록 최대한 많은 유저가 포함되는 복호 순서를 찾는 것이 중요하다.

이 경우 제한된 전체 전력으로 인해 유저들의 채널 상태에 따라 전력을 할당 받을 수 있는 유저 수가 일정하지 않다. 그러므로 서비스를 받는 유저 수를 1명부터 K 명까지 순차적으로 증가시키며 가능한 모든 복호 조합 순서에 대해 주어진 최대 전력 하에서 실현 가능한지 살펴보아야 한다. 따라서 총 K 명의 유저가 존재 할 때 고려되는 총 복호 조합 순서의 수 S 는 다음과 같다.

$$S = \sum_{i=1}^K K \Pi_i = \sum_{i=1}^K \frac{K!}{(K-i)!} \quad (8)$$

총 S 개의 복호 순서 중 임의의 s 번째 복호 순서를 고려하고, 이때 s 번째 복호 순서에서 서비스 되는 총 유저 수를 N_s 로 표시한다. 그러면 $n (\leq N_s)$ 번째로 복호되는 유저의 SINR인 $SINR_n^s$ 은 다음과 같이 표현된다.

$$SINR_n^s = \frac{p_n^s |h_n^{s\dagger} w_n^s|^2}{\sum_{i=1}^{n-1} p_i^s |h_n^{s\dagger} w_i^s|^2 + 1} \quad (9)$$

또한 s 번째 복호 순서에서 $m (< n)$ 번째로 복호되는 유저로부터 구하는 n 번째로 복호되는 유저의 SINR $SINR_{(m,n)}^s$ 은 다음과 같이 주어진다.

$$SINR_{(m,n)}^s = \frac{p_n^s |h_m^{s\dagger} w_n^s|^2}{\sum_{i=1}^{n-1} p_i^s |h_m^{s\dagger} w_i^s|^2 + 1} \quad (10)$$

이때 s 번째 복호 순서에서 m 번째 복호되는 유저가 얻는 n 번째로 복호되는 유저의 신호를 복호하기 위한 전력 $p_{(m,n)}^s$ 은 다음과 같이 계산되고

$$p_{(m,n)}^s = \gamma \cdot \left(\frac{\sum_{i=1}^{n-1} p_i^s |h_m^{s\dagger} w_i^s|^2 + 1}{|h_m^{s\dagger} w_n^s|^2} \right) \quad (11)$$

따라서 s 번째 복호 순서에서 n 번째로 복호되는 유저가 할당받아야 하는 전력 p_n^s 은 다음과 같다.

$$p_n^s \geq \max(p_{(1,n)}^s, \dots, p_{(n,n)}^s). \quad (12)$$

따라서 s 번째 복호 순서에서 서비스 받는 총 N_s 명의 유저를 서비스 하는데 필요한 최소 전력 P^s 는 다음과 같이 계산된다.

$$P^s = p_1^s + \dots + p_{N_s}^s. \quad (13)$$

이때 s 번째 복호 순서에서 얻을 수 있는 총 데이터 전송률은 R^s 는 다음과 같이 표현할 수 있다.

$$R^s = \begin{cases} N_s \log_2(1 + \gamma) & , P^s \leq P \\ 0 & , P^s > P \end{cases}. \quad (14)$$

전체 전력이 제한되어 있으므로 식 (14)에서 s 번째 복호 순서가 모든 유저에게 서비스 할 수 없는 경우, s 번째 복호 순서에서 얻을 수 있는 총 데이터 전송률을 0으로 나타내었다. 그러므로 고려하는 시스템에서의 최대 총 데이터 전송률 R_{\max} 은 다음과 같이 주어진다.

$$R_{\max} = \underset{1 \leq s \leq S}{\text{maximize}} R_s. \quad (15)$$

본 논문은 전체 송신 전력 하에서 최대 총 데이터 전송률을 갖는 복호 순서 s^* 을 구한다. 이는 다음과 같이 나타낼 수 있다.

$$s^* = \arg \max_{1 \leq s \leq S} \{ R^s \mid P^s \leq P \}. \quad (16)$$

III. 기계학습 기반 복호 기술

본 장에서는 일반적인 심층 신경망에 대해 간단히 설명한 후 복호 순서 결정을 위한 기계학습 모델을 제안한다.

3.1 일반적인 심층 신경망 모델

그림 2에 나타난 것과 같이 일반적인 심층 신경망 모델은 입력 층과 출력 층 사이에 다수의 은닉 층이

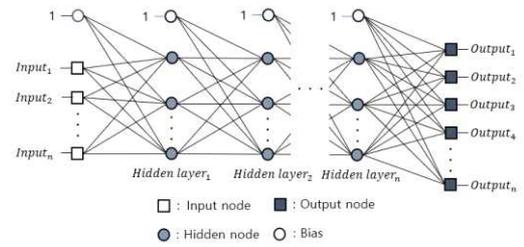


그림 2. 일반적인 심층 신경망(DNN) 모델
Fig. 2. An example of a DNN model

존재하는 구조를 갖는다. 심층 신경망 모델의 성능을 좌우하는 중요한 요소 중 하나는 각 층들의 노드 간에 존재하는 가중치(weight)인데, 이때 모델의 성능을 최대화하는 최적의 가중치는 입력 층에서 출력 층의 방향으로 진행하는 학습과 출력 층에서 입력 층의 방향으로 진행하며 가중치의 오류를 수정하는 오류 역전파 알고리즘을 순차적으로 반복하며 얻는다. 또한 입력 노드를 제외한 은닉 및 출력 노드에는 활성화 함수가 존재하며 주로 출력 노드의 학습 데이터 형태에 따라 최적의 활성화 함수가 결정된다.

3.2 제안하는 복호 기술의 기계학습 모델

그림 3은 본 논문에서 제안하는 기계학습 모델을 나타낸다. 본 논문은 기계학습을 활용하여 총 K 명의 유저가 존재하고 전체 전력이 제한된 MISO NOMA 브로드캐스트 채널 시스템에서 각 유저들 간의 채널 상관관계와 전체 전력을 고려하여 식 (8)에서 구한 총 S 개의 복호 순서 중 최적의 복호 순서를 찾는다. 먼저 총 K 명의 유저가 존재하므로, 입력 층에 다음과 같이 모든 유저 간 채널 상관관계 값을 넣는다.

$$|\mathbf{h}_i^\dagger \mathbf{h}_j|^2, \quad i, j = 1, \dots, K. \quad (17)$$

이때 채널 상관관계 수는 총 $K C_2 (= (K^2 + K)/2)$ 개이다. 또한, 채널 품질을 나타내기 위한 신호 대 잡음

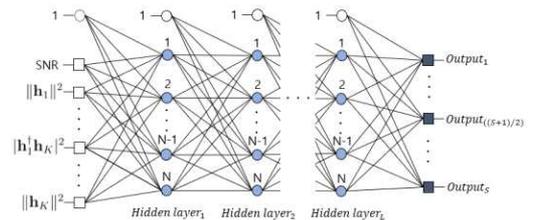


그림 3. 본 논문에서 제안하는 기계학습 모델
Fig. 3. Proposed machine learning model

전력비 (signal-to-noise power ratio, SNR)도 함께 입력 노드에 입력된다. 그러므로 제안하는 기계학습 모델은 총 $(K^2 + K)/2 + 1$ 개의 입력 노드를 갖는다.

은닉 층의 경우 각각 N 개의 은닉 노드를 갖는 L 개의 은닉 층으로 구성된다. 그리고 제안하는 기계학습 모델은 다층 구조를 갖는 모델이므로 은닉 노드의 활성화 함수로 rectified linear unit (ReLU) 함수를 사용한다. 일반적으로 은닉 노드의 활성화 함수로 sigmoid 함수도 많이 사용되지만, 0과 1사이의 값을 갖는 sigmoid 함수는 다층 구조를 갖는 기계학습 모델의 은닉 노드 활성화 함수로 사용될 경우 학습이 진행됨에 따라 gradient가 0에 근접한 값으로 수렴할 확률이 높다. 그러므로 0에서 무한대의 값을 갖는 ReLU 함수를 은닉 노드의 활성화 함수로 사용하는 것이 타당하다.

K 명의 사용자가 존재할 때 식 (8)에서 구한 총 S 개의 복호 순서가 존재하므로 출력 층은 총 S 개의 출력 노드를 갖는다. 그러므로 입력 데이터가 주어졌을 때 각각의 출력 노드가 최적의 출력 노드로 선택될 확률을 출력 데이터로 형성하는 softmax 함수를 각 출력 노드의 활성화 함수로 사용한다. 따라서 출력 데이터들이 확률이므로 각각의 출력 데이터들의 합은 1을 넘지 않으며 가장 높은 출력 데이터를 갖는 출력 노드가 최적의 복호 순서가 된다.

기계학습의 성능을 결정짓는 요소 중 하나인 가중치의 오류를 구하는 손실 함수(loss function)는 일반적인 기계학습 모델에서 널리 사용되는 교차 엔트로피(cross entropy) 함수를 사용하였으며 다음과 같이 정의된다.

$$e = \sum_{i=1}^S (l_i (\log_2 o_i) + (1 - l_i) \log_2 (1 - o_i)). \quad (18)$$

여기서 l_i 는 데이터의 i 번째 레이블을 의미한다, 이때 S 개의 레이블 중 정답인 레이블만 1의 값을 갖고 나머지는 0의 값을 가지므로 $l_i \in \{0, 1\}$ 로 표현된다. o_i 는 i 번째 출력 노드의 출력 데이터이다. 또한 최적화 알고리즘으로는 adaptive momentum (AdaM) 알고리즘을 사용하며 과적합을 막기 위해서 초기 학습률은 0.001로 한다. 또한 손실 값이 연속으로 10번 일정할 경우 학습을 중단하는 규제 기법을 사용한다. 배치 사이즈는 260으로 하며 최대 반복 횟수(epoch)는 1000으로 한다.

IV. 실험 결과

본 논문은 각 유저들에게 서비스 되는 데이터 전송률이 1bit 일 때 (즉, SINR이 $\gamma = 1$ 로 고정될 때), 임의의 세 명의 유저가 있는 시스템에서 제안하는 기계학습 모델의 성능을 평가하였다. 따라서 고려되는 유저 간의 채널 상관관계는 총 6개이며 SNR도 함께 입력되므로 제안하는 기계학습 모델은 총 7개의 입력 노드를 갖는다. 식 (8)에 기술한 바와 같이 세 명의 유저가 존재할 때 가능한 총 복호 순서는 15개이므로, 제안하는 기계학습 모델은 총 15개의 출력 노드를 갖는다. 또한 각각 75개의 은닉 노드를 가지는 두 개의 은닉 층을 고려하였다.

제안하는 기계학습 모델의 성능 평가를 위해, 학습을 위한 세 가지 샘플 데이터 수(1만, 3만, 5만 샘플)를 고려하였다.

이 중에서 80%의 샘플 데이터는 training 데이터로, 나머지 20%는 training 데이터로 학습된 모델의 오류를 검증하여 모델의 성능을 향상시키는 validation 데이터로 사용하였다. 일반적으로 학습 데이터가 많을수록 높은 정확도를 보이나 과도하게 많을 경우 지나치게 학습 데이터에 과적합된 기계학습 모델이 형성될 수 있으므로 적절한 학습 데이터를 사용하는 것이 중요하다.

세 가지 모델의 비교를 위해 학습 데이터 수에 상관없이 모두 동일한 5000개의 test 데이터를 사용하였다. 성능 평가 결과 학습 데이터 수가 증가할수록 정확도는 상승하였으며 학습 데이터의 수가 1만개 일 때는 평균적으로 97.42%의 정확도를 보였으며 3만개와 5만개 일 때는 각각 평균적으로 97.48%와 98.41%의 정확도를 보였다.

그림 4는 성능 평가 결과 얻은 각 유저들의 총 데이터 전송률을 나타낸다. 여기서 optimal 기법은 본 논문에서 제안하는 기계학습 모델을 활용하지 않고 반복적으로 구한 최적의 복호 순서로부터 얻은 총 데이터 전송률을 의미한다. Optimal 기법 이외에 그림 4에 존재하는 서로 다른 세 개의 총 데이터 전송률은 본 논문에서 고려한 세 개의 서로 다른 학습 데이터 수 조건에서 기계학습을 활용하여 구한 최적의 복호 순서로부터 얻은 총 데이터 전송률이다. 각각의 서로 다른 학습 데이터 수 하에서 얻은 총 데이터 전송률들은 optimal과 유사하며 특히 학습 데이터 수가 1만에서 5만으로 증가할수록 성능이 증가하는 것을 알 수 있다. 좀 더 자세히 기계학습 모델의 정확도를 확인하기 위해 optimal을 기준으로 정규화한 유저들의 총 데

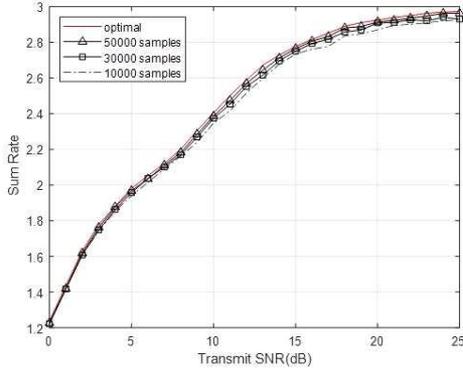


그림 4. 유저들의 총 데이터 전송률
Fig. 4. The sum achievable rates of various schemes

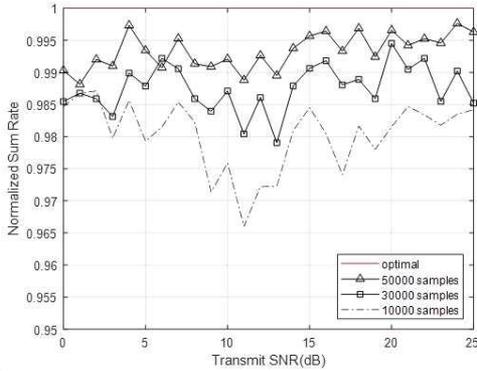


그림 5. 정규화한 유저들의 총 데이터 전송률
Fig. 5. The normalized sum achievable rates of various schemes

이더 전송률을 그림 5에 나타내었다. 그림 5에서도 그림 4와 마찬가지로 학습 데이터 수가 1만에서 5만으로 증가할수록 총 데이터 전송률이 optimal과 더 비슷해지는 것을 확인할 수 있다. 따라서 제안하는 기계학습 모델이 optimal 기법에 근접한 성능을 얻는 것을 볼 수 있다.

V. 결 론

본 논문은 각 유저들이 얻어야 하는 SINR이 고정된 MISO NOMA 브로드캐스트 채널에서 각 유저 간의 채널 상관관계를 이용하여 고려되는 복호 순서 중 최대 총 데이터 전송률을 갖는 최적의 복호 순서를 찾는 기계학습 모델을 제안하였다. 제안하는 기계학습 모델의 성능은 세 명의 유저가 존재하는 시스템에서 기계학습을 활용하지 않고 구한 최적의 복호 순서와 기계학습을 활용하여 구한 최적의 복호 순서의 총 데

이터 전송률을 비교하여 평가하였으며 각각의 총 데이터 전송률은 서로 높은 유사도를 보였다. 제안하는 기계학습 모델은 유저 수가 증가할수록 비교해야 하는 복호 순서가 증가하여 더 많은 양의 학습 데이터가 요구되지만, 오프라인에서 학습을 마친 기계학습 모델은 변화하는 채널 하에서 일정한 복잡도로 복호 순서를 찾아낼 수 있다.

References

- [1] J. Kaur, M. A. Khan, M. Iftikhar, M. Imran, and Q. E. U. Haq, "Machine learning techniques for 5g and beyond," *IEEE Access*, vol. 9, pp. 23472-23488, Feb. 2021.
- [2] A. Shrestha and A. Mahmood, "Review of deep learning algorithms and architectures," *IEEE Access*, vol. 7, pp. 53040-53065, May 2019.
- [3] Y. Huang, C. Zhang, J. Wang, Y. Jing, L. Yang, and X. You, "Signal processing for MIMO-NOMA: Present and future challenges," *IEEE Wireless Commun.*, vol. 25, no. 2, pp. 32-38, Apr. 2018.
- [4] M. F. Hanif, et al., "A minorization-maximization method for optimizing sum rate in the downlink of non-orthogonal multiple access systems," *IEEE Trans. Signal Process.*, vol. 64, no. 1, pp. 76-88, Jan. 2016.
- [5] J. Zhu, J. Wang, Y. Huang, K. Navaie, Z. Ding, and L. Yang, "On optimal beamforming design for downlink MISO NOMA systems," *IEEE Trans. Veh. Technol.*, vol. 69, no. 3, pp. 3008-3020, Mar. 2020.
- [6] G. Interdonato, H. Q. Ngo, and E. G. Larsson, "Enhanced normalized conjugate beamforming for cell-free massive MIMO," *IEEE Trans. Commun.*, vol. 69, no. 5, pp. 2863-2877, May 2021.
- [7] J. Kim, H. Lee, S. Hong, and S. Park, "Deep learning methods for universal MISO beamforming," *IEEE Wireless Commun. Lett.*, vol. 9, no. 11, pp. 1894-1898, Nov. 2020.
- [8] H. Huang, W. Xia, J. Xiong, J. Yang, G. Zheng, and X. Zhu, "Unsupervised learning-based fast beamforming design for downlink

MIMO,” *IEEE Access*, vol. 7, pp. 7599-7605, Jan. 2019.

- [9] Z. Zhao, D. Wang, H. Zhang, and H. Sang, “Joint user pairing and power allocation scheme based on transmission mode switching between NOMA-based maximum ratio transmission and MMSE beamforming in downlink MISO systems,” *Mob. Inf. Syst.*, vol. 2021, Art. ID. 6671371, Mar. 2021.
- [10] M. Aldababsa, M. Toka, S. Gökçeli, G. K. Kurt, and O. Kucur, “A tutorial on nonorthogonal multiple access for 5G and beyond,” *Wireless Commun. and Mob. Comput.*, vol. 2018, Art. no. 9713450, Feb. 2018.
- [11] Z. Ali, G. A. S. Sidhu, F. Gao, J. Jiang, and X. Wang, “Deep learning based power optimizing for NOMA based relay aided D2D transmissions,” *IEEE Trans. Cognit. Commun. Netw.*, vol. 7, no. 3, pp. 917-928, Sep. 2021.
- [12] D. H. Kim, I. H. Lee, “User association and power allocation scheme using deep learning algorithm in non-orthogonal multiple access based heterogeneous networks,” *Journal of the Korea Institute of Information and Communication Engineering (JKIICE)*, vol. 26, no. 3, pp. 430-435, Mar. 2022.
- [13] H. Huang, Y. Yang, Z. Ding, H. Wang, H. Sari, and F. Adachi, “Deep learning-based sum data rate and energy efficiency optimization for MIMO-NOMA systems,” *IEEE Trans. Wireless Commun.*, vol. 19, no. 8, pp. 5373-5388, Aug. 2020.
- [14] M. Liu, T. Song, and G. Gui, “Deep cognitive perspective: Resource allocation for NOMA-based heterogeneous IoT with imperfect SIC,” *IEEE Internet of Things J.*, vol. 6, no. 2, pp. 2885-2894, Apr. 2019.

강민정 (Min Jeong Kang)



2020년 2월 : 한국외국어대학교
공학사, 이학사
2020년 2월~현재 : 한국외국어
대학교 공학석사과정
<관심분야> 무선통신시스템, 기
계학습
[ORCID:0000-0001-7714-1504]

이정훈 (Jung Hoon Lee)



2006년 6월 : 한국과학기술원 공
학사
2008년 8월 : 한국과학기술원 공
학석사
2013년 8월 : 한국과학기술원 공
학박사
2013년 9월~2014년 4월 : 한국
과학기술원 박사후연구원
2014년 8월~2015년 8월 : 미국 노스캐롤라이나 주립대
학교 박사후연구원
2015년 9월~2016년 8월 : 국립제주대학교 전자공학과
조교수
2016년 9월~2021년 8월 : 한국외국어대학교 전자공학
과 조교수
2021년 9월~현재 : 한국외국어대학교 전자공학과 부교수
<관심분야> 간섭 제어, 위성 통신, 기계 학습
[ORCID:0000-0002-7875-2398]