

두 유저 MISO 간섭채널에서 머신러닝을 활용한 빔포밍 기술

권형준*, 이정훈°, 최완*

Machine Learning-Based Beamforming in Two-User MISO Interference Channels

Hyung Jun Kwon*, Jung Hoon Lee°, Wan Choi*

요약

데이터 전송속도에 대한 요구가 증가함에 따라 소형화되는 셀 크기로 인해 발생하는 간섭 문제는 향후 무선 통신 기술의 발전을 위해 극복해야 할 주요한 과제로 떠오르고 있다. 본 논문에서는 두 사용자 MISO 간섭채널에서 머신러닝 모델을 활용하여 빔포밍 조합을 구하고 그 성능을 보인다. 특히 maximum ratio transmission (MRT) 빔포밍 기법과 zero-forcing (ZF) 빔포밍 기법 중 하나를 선택하여 사용하는 간단한 빔포밍 기법에 머신러닝을 적용함으로써, 차후 다양한 간섭채널에서 머신러닝 빔포밍 기법의 적용 가능성을 연구한다. 본 논문에서는 머신러닝 모델을 이용하여 전력과 채널 상태에 따른 빔포밍 조합을 구하고 직접 계산한 최적의 빔포밍 조합과 비교하여 모델의 정확도를 측정한다. 또한 송신단들의 전송률 합을 비교하여 성능을 검증한다.

Key Words : Machine learning, MISO interference channel, deep neural network, beamforming, artificial intelligence

ABSTRACT

As the demand for data rate increases, interference management becomes more important especially in small cell environment of emerging wireless communication systems. In this paper, we investigate the machine learning-based beamforming design in two-user MISO interference channels. To see the possibilities of machine learning in beamforming design, we consider simple beamforming, where each user chooses one between two popular beamforming schemes, which are the maximum ratio transmission (MRT) beamforming and the zero-forcing (ZF) beamforming. We first propose a machine learning structure that takes transmit power and channel vectors as inputs and then recommends two users' choices between MRT and ZF as an output. The numerical results show that our proposed machine learning-based beamforming design well finds the best beamforming combination and achieves the sum-rate more than 99.9% of the best beamforming combination.

* This work was supported by Hankuk University of Foreign Studies Research Fund of 2018 and by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT) (No. NRF-2016R1C1B2010281).

• First Author : (ORCID:0000-0001-9007-5871)Department of Electronics Engineering and Applied Communications Research Center, Hankuk University of Foreign Studies, hjkwon91@hufs.ac.kr, 학생회원

° Corresponding Author : (ORCID:0000-0002-7875-2398)Department of Electronics Engineering and Applied Communications Research Center, Hankuk University of Foreign Studies, tantheta@hufs.ac.kr, 정회원

* (ORCID:0000-0003-3930-7088)School of Electrical Engineering, Korea Advanced Institute of Science and Technology, wchoi@kaist.edu, 종신회원

논문번호 : 201810-332-A-RN, Received October 16, 2018; Revised January 7, 2019; Accepted January 24, 2019

I. 서 론

4차 산업혁명 시대가 도래함에 따라 현대 사회는 급격한 변화를 겪고 있고 우리 삶 또한 많은 부분이 변하고 있다. 그 중심에 있는 인공지능 기술은 산업과 사회 각 분야에 접목되어 새로운 가치를 창출하고 있다. 인공지능은 인간만 할 수 있다고 생각되었던 학습, 추론, 인지 등 인간이 지닌 능력의 일부 또는 전체를 인공적으로 구현한 것이며, 인간이 할 수 있는 일을 기계가 수행하게 하는 것을 목표로 한다. 최근에는 인공지능을 구현하기 위한 핵심 기술로 머신러닝이 주목받고 있다. 머신러닝은 기계가 경험의 시행착오를 통해 스스로 학습함으로써 성능을 향상시키는 인공지능 기술이다. 머신러닝은 우리가 깨닫지 못하고 있는 사이에 검색어 자동 완성 기능, 휴대전화 음성인식 기능, 스팸 메일 자동 차단 기능 등 이미 우리 일상에 깊이 들어와 있다.

머신러닝이 이토록 각광받게 된 요인으로는 딥 러닝 기술의 등장이 큰 영향을 끼쳤다. 딥 러닝은 기존 방법들을 압도하는 성능을 보이며 머신러닝 분야에서 핵심 기술로 자리 잡고 있다. 딥 러닝 기술은 새로운 이론이나 기술이 아니라 기존 인공 신경망의 구조를 깊게 만드는 것으로써, 80년대에 이미 그 아이디어가 발표되었다. 그러나 layer를 추가하여 깊은 구조를 만들면 학습이 제대로 진행되지 않거나 과도한 계산 시간 등 여러 문제가 발생하여 사용되지 않았다. 이러한 상황에서도 일부 연구자들에 의해 연구가 계속 진행되었고, 앞서 기술한 한계점들에 대한 여러 가지 방안이 제시되면서 점차 활발히 사용되기 시작하였다^[1].

먼저, convolution neural network (CNN)가 소개되면서^[2], 기존의 layer 간 모든 노드가 서로 연결된 완전연결 구조가 아닌 부분연결 구조를 사용하여 모델 복잡도를 낮추고, 영상처리나 신호처리 분야에서 일반적으로 사용하는 컨볼루션 연산을 적용함으로써 인간이 개입하지 않아도 컴퓨터 스스로 특징을 추출할 수 있게 되었다. 또한, graphics processing units (GPU)의 등장으로 병렬 처리를 할 수 있게 되어 학습 시간이 단축되었고^[3], 저렴한 GPU가 등장하면서 쉽게 활용할 수 있게 되었다. 더불어 인터넷의 활용으로 인해 데이터 규모가 크게 늘었고, 딥 러닝 모델의 성능을 향상시키는 활성화 함수, 비용 함수, 규제 기법 등이 개발되면서 딥 러닝의 기존 한계점들이 많이 극복되었다.

머신러닝의 발전과 함께, 무선 통신 기술 또한 급격히 발전하여 차세대 무선 통신 기술인 5G/6G 시대에

이르렀다. 그러나 그만큼 어플리케이션, 디바이스, 네트워크 간 이질성을 포함한 여러 요구사항을 고려해야 하므로, 시스템이 복잡해지고 있다. 따라서 시스템 내 사용 가능한 자원들을 이용하여 좀 더 높은 효율을 얻는 방법이 요구되었고, 그에 따라 기존 접근 방식들은 미래의 복잡한 시스템에 만족스러운 서비스를 제공할 수 없다^[4]. 이러한 문제의 해결방안 중 하나로, 무선 통신 시스템에 머신러닝을 적용하여 효율을 극대화하려는 연구가 활발하게 진행되고 있다. 논문 [5]에서는, IEEE 802.11 wireless local area networks (WLANs)에서 채널 상태만 고려하여 프레임 크기를 최적화하는 기존 방법과는 다르게, 머신러닝 모델을 통해 채널 상태와 충돌 상황을 모두 고려하여 프레임 크기를 최적화함으로써 시스템 성능을 향상시킬 수 있음을 보였다. 또한 논문 [6]에서는, 무선 네트워크 환경에서 packet loss가 발생하였을 때, 충돌로 인한 loss인지 링크 에러로 인한 loss인지를 판단하는 알고리즘으로 머신러닝 기술을 채택하였으며, 머신러닝의 여러 알고리즘을 적용하여 그 성능을 비교하였다. 그 외에도 머신러닝을 통신 시스템에 적용하기 위한 다양한 연구가 활발히 진행되고 있다^[7-10].

무선 통신 기술의 발달로 인한 데이터 이용량의 폭발적인 증가에 따라, 한정된 주파수 대역에서 사용자 용량을 높이는 방법에 대한 연구가 오래전부터 진행되어 왔다. 현재 그 핵심 기술로, 서비스하는 지역을 셀 단위로 분할하여 일정 거리 마다 주파수를 재사용하는 주파수 재사용 개념이 사용되고 있다. 셀 크기의 소형화는 시스템 용량을 증가시키며, 그로 인해 데이터 전송속도는 향상된다. 그러나 동시에 인접 셀 간 간섭이 증가하고, 이는 시스템 성능 저하로 이어진다. 데이터 전송속도에 대한 요구가 증가함에 따라 소형화되는 셀 크기로 인해 발생하는 간섭 문제는 향후 무선 통신 기술의 발전을 위해 극복해야 할 주요한 과제이다^[11]. 따라서 간섭을 제어하기 위해 안테나의 빔을, 서비스하는 사용자에 맞추어 비추는 빔포밍 기술에 대한 연구가 활발히 진행되어왔다. 두 유저 MISO 간섭채널에서 전송량을 최대로 하는 빔포밍 벡터는 여러 채널 벡터의 선형결합을 통해 얻어 진다는 사실은 이미 밝혀졌지만^[12] 구하는 것이 쉽지 않다.

본 논문에서는 선형결합은 고려하지 않고 각 송신단이 MRT와 ZF 빔포밍 벡터중 하나를 선택하여 사용하는 환경에서, 머신러닝을 활용하여 송신단들의 빔포밍 조합을 구한다. 이처럼 간단한 환경에서 머신러닝 모델의 성능을 보임으로써, 간섭 문제 해결에 대한 머신러닝 기술 적용 가능성을 연구한다. 제안하는 머

신러닝 모델은 심층 신경망 구조를 가지며, 두 유저 MISO 간섭채널에서 채널 상태를 고려하여 송신단의 전송량 총 합을 최대로 하는 MRT와 ZF 빔포밍 벡터의 조합을 찾는다. 직접 구한 최적의 빔포밍 조합의 전송량 합과 머신러닝 모델을 통하여 구한 조합의 전송량 합을 비교하여 모델의 성능을 측정한다.

본 논문은 다음과 같이 구성된다. II장에서는 두 유저 MISO 간섭채널에 대해 설명하고, III장에서는 일반적인 심층 신경망 모델과 제안하는 머신러닝 모델을 소개한다. 그 다음으로 IV장에서는 제한한 머신러닝 모델의 학습 능력을 확인하고, 모델을 이용해 빔포밍 조합을 구하여 그 성능을 검증한다. 마지막으로 V장에서 결론을 맺는다.

II. 시스템 모델

본 논문에서 고려하는 시스템 모델은 그림 1에 나타나있다. 두 개의 안테나를 가진 두 송신단이 한 개의 안테나를 가진 두 유저를 각각 서비스하는 MISO 간섭채널 환경을 고려한다. 각 유저는 자신을 서비스하는 송신단의 신호 외에도 다른 송신단으로부터 다른 유저에게 보내는 신호를 간섭 신호로 받는다. 송신단은 채널 상태 정보를 알고 있다고 가정한다. i 번째 유저가 수신하는 신호는 다음과 같이 표현된다^[12].

$$y_i = \mathbf{h}_{ii}^T \mathbf{x}_i + \eta \mathbf{h}_{ij}^T \mathbf{x}_j + n_i, \quad i \neq j. \quad (1)$$

여기서 $\mathbf{h}_{ij} \in \mathbb{C}^{2 \times 1}$ 는 j 번째 송신단으로부터 i 번째 유저까지의 벡터 채널로서 다음과 같이 주어진다.

$$\mathbf{h}_{11} = \begin{bmatrix} h_{11}^{(1)} \\ h_{11}^{(2)} \end{bmatrix}, \mathbf{h}_{12} = \begin{bmatrix} h_{12}^{(1)} \\ h_{12}^{(2)} \end{bmatrix}, \mathbf{h}_{21} = \begin{bmatrix} h_{21}^{(1)} \\ h_{21}^{(2)} \end{bmatrix}, \mathbf{h}_{22} = \begin{bmatrix} h_{22}^{(1)} \\ h_{22}^{(2)} \end{bmatrix}.$$

본 논문에서는 Rayleigh 채널 분포를 고려한다. 따라서 벡터 채널의 각 원소는 평균 0 분산 1인 복소 가우시안 변수로 모델링 한다. $(\cdot)^T$ 는 전치 연산을 나타내고, \mathbf{x}_i 는 i 번째 송신단이 자신이 서비스하는 유저에게 송신하는 신호이다. 실제 간섭 채널은 유저들의 채널보다 작을 수 있으므로 η 를 두어 자신의 채널과 간섭 채널의 비율을 모델링한다^[13]. $n_i \in \mathbb{C}^{1 \times 1}$ 는 i 번째 유저가 수신하는 평균이 0, 분산이 1인 백색 가우시안 노이즈이다.

선형 빔포밍 기법을 사용할 때 송신 데이터 \mathbf{x}_i 는

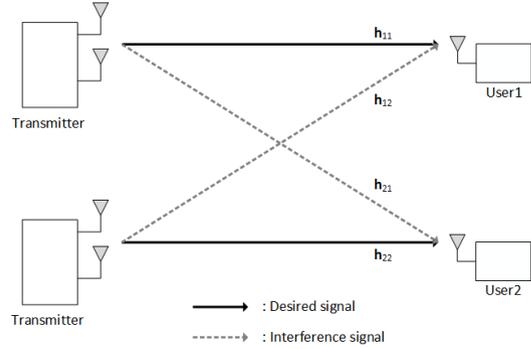


그림 1. 두 유저 MISO 간섭채널
Fig. 1. The two-user MISO interference channel

다음과 같이 표현될 수 있다.

$$\mathbf{x}_i = \sqrt{P_i} \mathbf{w}_i s_i. \quad (2)$$

여기서 P_i 는 i 번째 송신단의 전송 파워, $\mathbf{w}_i \in \mathbb{C}^{2 \times 1}$ 는 빔포밍 벡터, $s_i \in \mathbb{C}^{1 \times 1}$ 는 데이터 심볼을 나타낸다. 여기서 \mathbf{x}_i 의 파워는 $E[\|\mathbf{x}_i\|^2] = P_i$ 이고, $\|\mathbf{w}_i\|^2 = |s_i|^2 = 1$ 라고 가정한다. 본 논문에서는 각 전송단이 최대 전력 P 를 사용하는 경우만 고려한다 (즉, $P_i = P$).

따라서 빔포밍 벡터 \mathbf{w}_1 와 \mathbf{w}_2 를 사용할 때, 각 송신단이 얻는 전송량은 다음과 같이 주어진다^[14].

$$R_1(\mathbf{w}_1, \mathbf{w}_2) = \log_2 \left(1 + \frac{P |\mathbf{h}_{11}^T \mathbf{w}_1|^2}{1 + \eta^2 P |\mathbf{h}_{12}^T \mathbf{w}_2|^2} \right), \quad (3)$$

$$R_2(\mathbf{w}_1, \mathbf{w}_2) = \log_2 \left(1 + \frac{P |\mathbf{h}_{22}^T \mathbf{w}_2|^2}{1 + \eta^2 P |\mathbf{h}_{21}^T \mathbf{w}_1|^2} \right). \quad (4)$$

채널 환경에 따라 다양한 빔포밍 기법이 존재하지만, 널리 사용되는 기법으로는 MRT와 ZF 빔포밍 기법이 있다. MRT 빔포밍은 signal-to-noise ratio (SNR)를 최대화 하는 방법으로, 송신단은 간섭 신호를 전혀 고려하지 않고 자신이 서비스하는 유저의 채널만 고려한다. 송신단 i 에서 MRT 빔포밍 벡터는 다음과 같이 나타낼 수 있다^[15].

$$\mathbf{w}_i^{(MRT)} = \frac{\mathbf{h}_{ii}^*}{\|\mathbf{h}_{ii}^*\|}. \quad (5)$$

여기서 $(\cdot)^*$ 는 벡터의 켈레 벡터를 나타낸다. 이 때 SNR은 $P \|\mathbf{h}_{ii}\|^2$ 가 된다.

하지만, 실제 시스템에서는 간섭 신호가 존재하기 때문에 간섭 신호가 셀 경우, SNR을 최대로 하는 빔포밍 벡터를 구성하는 것이 효율적이지 않다. 이때 널리 쓰이는 방법 중 하나로서 ZF 빔포밍은 간섭 채널들과 직교하도록 빔포밍 벡터를 구성하여 간섭 신호를 0으로 만든다. 송신단 i 의 ZF 빔포밍 벡터는 다음과 같이 나타낼 수 있다¹⁵⁾.

$$\mathbf{w}_i^{(ZF)} = \frac{\mathbf{h}_{ii}^* - \widetilde{\mathbf{h}}_{ij} \widetilde{\mathbf{h}}_{ij}^\dagger \mathbf{h}_{ii}^*}{\|\mathbf{h}_{ii}^* - \widetilde{\mathbf{h}}_{ij} \widetilde{\mathbf{h}}_{ij}^\dagger \mathbf{h}_{ii}^*\|}, \quad i \neq j. \quad (6)$$

여기서 $(\cdot)^\dagger$ 는 벡터의 켈레전치 벡터를 나타내고 $\widetilde{\mathbf{h}}_{ij}$ 는 \mathbf{h}_{ij} 의 방향으로 $\widetilde{\mathbf{h}}_{ij} := \mathbf{h}_{ij} / \|\mathbf{h}_{ij}\|$ 이다. MRT 빔포밍은 간섭채널이 자신의 채널보다 약해질수록, ZF 빔포밍 기법은 간섭 채널이 자신의 채널보다 강해질수록 최적의 빔포밍 기법에 가까워진다.

채널 상태 \mathbf{h}_{ii} 와 전력 P 에 따라 같은 빔포밍 벡터를 사용하여도 얻을 수 있는 전송량이 다르기 때문에, 특정 빔포밍 벡터가 항상 좋은 성능을 보장하지는 않는다. 일반적으로 두 유저 MISO 간섭채널에서 모든 송신단이 얻을 수 있는 전송량의 합을 최대로 하는 빔포밍 벡터는 다음과 같이 MRT 빔포밍 벡터와 ZF 빔포밍 벡터의 선형 결합으로 얻을 수 있다는 것이 알려져 있다¹²⁾.

$$\mathbf{w}_i(\alpha_i) = \frac{(1 - \alpha_i) \mathbf{w}_i^{(MRT)} + \alpha_i \mathbf{w}_i^{(ZF)}}{\|(1 - \alpha_i) \mathbf{w}_i^{(MRT)} + \alpha_i \mathbf{w}_i^{(ZF)}\|}. \quad (7)$$

본 논문은 빔포밍 벡터 구성에 대한 머신러닝의 적용 가능성을 연구하는 것을 목표로 한다. 따라서 두 벡터의 선형결합을 고려하지 않고 α_i 가 0 또는 1인 경우만 고려한다. 이는 MRT 또는 ZF 빔포밍 둘 중 하나를 선택하여 사용하는 것으로, $\alpha_i = 0$ 인 경우는 MRT 빔포밍 기법, $\alpha_i = 1$ 인 경우는 ZF 빔포밍 기법에 해당한다 (즉, $\mathbf{w}_i(0) = \mathbf{w}_i^{(MRT)}$, $\mathbf{w}_i(1) = \mathbf{w}_i^{(ZF)}$). 송신단 i 의 빔포밍 전략을 $s_i \in \{MRT, ZF\}$ 라고 할 때, 빔포밍 조합은 (s_1, s_2) 로 나타낼 수 있다. 따라서 고려하는 환경에서 두 유저 빔포밍은 MRT와 ZF를 결합한 네 가지 조합(S)으로 나타낼 수 있다.

$$S = \left\{ (MRT, MRT), (MRT, ZF), (ZF, MRT), (ZF, ZF) \right\}. \quad (8)$$

이 때, 전송량의 합을 최대화하는 빔포밍 조합을 찾는 문제는 다음과 같이 나타낼 수 있다.

$$\underset{(s_1, s_2) \in S}{\text{maximize}} R_1(\mathbf{w}_1^{(s_1)}, \mathbf{w}_2^{(s_2)}) + R_2(\mathbf{w}_1^{(s_1)}, \mathbf{w}_2^{(s_2)}). \quad (9)$$

III. 머신러닝 기반 빔포밍 기술

본 논문에서 제안하는 머신러닝 기반 빔포밍 기술에서는 심층 신경망으로 구성된 머신러닝 모델을 이용한다. 다음 절에서는 심층 신경망의 일반적인 모델과 제안하는 머신러닝의 모델을 각각 설명한다.

3.1 심층 신경망의 일반적인 모델

그림 2에 나타낸 것과 같이 심층 신경망은 입력층, 다수의 은닉층, 출력층으로 구성된다. 입력층에서 샘플 데이터가 입력되면, 입력값은 은닉층의 각 노드에서 가중치와 bias가 각각 곱해지고 더해진 후 사용자가 설정한 활성화함수를 거쳐 해당 은닉노드의 출력이 된다. 모든 은닉층을 거쳐 출력층의 각 출력노드에서 최종 출력 값이 결정되며, 머신러닝 모델은 샘플 데이터를 가장 큰 출력 값을 가진 출력노드가 나타내는 label로 분류한다. 전방 계산이 끝나게 되면, 주어진 샘플과 모델의 출력을 사용자가 설정한 비용함수를 이용하여 오류를 추정할 수 있다. 모델은 출력 층에서 시작하여 반대 방향으로 오류를 전파함으로써 미리 설정된 알고리즘에 의해 오류를 줄이는 방향으로 가중치를 갱신하여 정확도를 높인다.

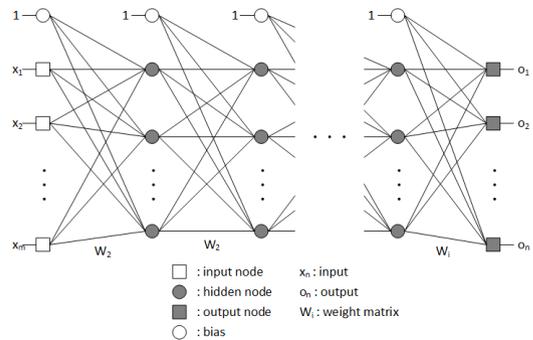


그림 2. 심층 신경망의 일반적인 모델
Fig. 2. A general model of a deep neural network (DNN)

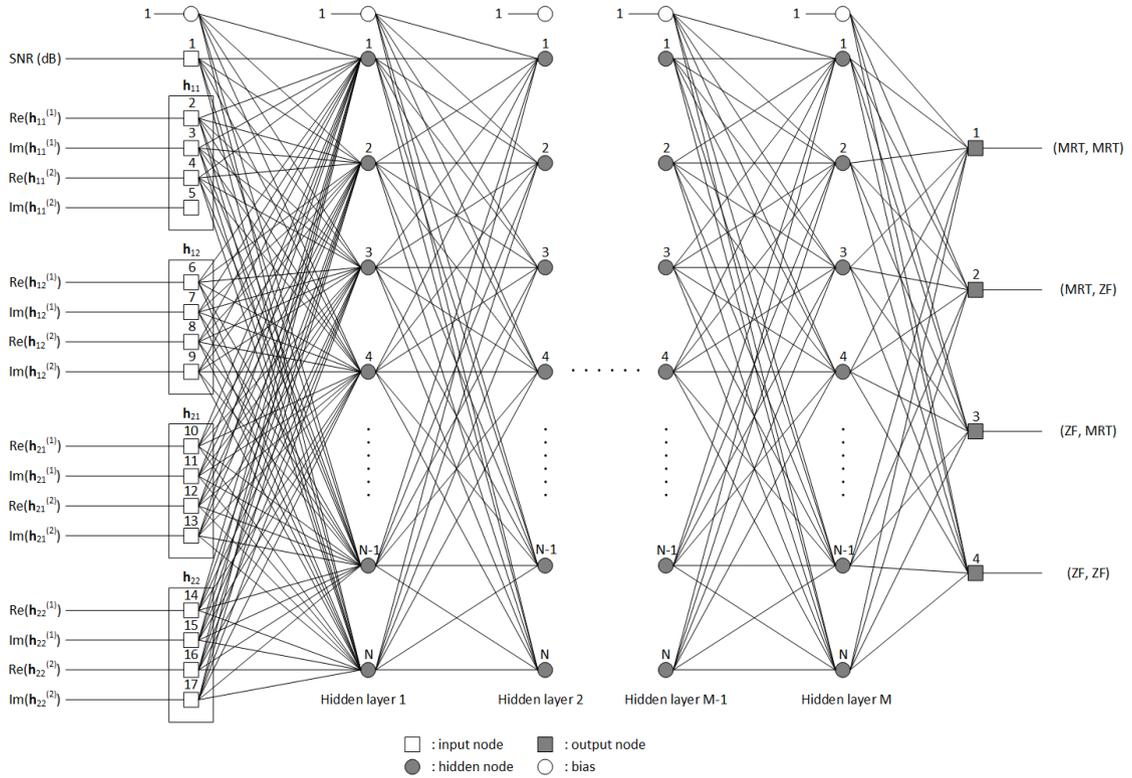


그림 3. 제안하는 머신러닝 모델
Fig. 3. The proposed machine learning model

3.2 제안하는 머신러닝 모델

본 논문에서 제안하는 머신러닝 모델은 그림 3에 나타난 것과 같이 17개의 입력 노드, N개의 은닉노드, M개의 은닉층, 4개의 출력 노드를 가진다.

3.2.1 입력 층

본 논문에서는 두 유저 MISO 간섭 채널을 고려하므로 자신의 채널과 간섭 채널을 합쳐 총 4개의 벡터 채널이 생성된다. 이때 각 벡터 채널은 2×1 복소 채널이 되므로, 각 벡터 채널 당 실수부 허수부를 합쳐 총 4개의 채널 값이 주어지게 된다. 예를 들어 벡터 채널 $\mathbf{h}_{11} = [h_{11}^{(1)}, h_{11}^{(2)}]^T$ 을 나타내기 위해 총 네 개의 실수 값 $Re(h_{11}^{(1)})$, $Im(h_{11}^{(1)})$, $Re(h_{11}^{(2)})$, $Im(h_{11}^{(2)})$ 이 필요하다. 따라서 네 개의 벡터 채널은 총 16개의 실수 값의 feature로서 나타낼 수 있다. 그러므로 제안하는 모델의 입력 층은 1개의 전력 값(혹은 SNR)과 16개의 채널 상태 값으로 총 17개의 입력 노드를 가진다.

3.2.2 은닉층

이전에는 은닉 노드의 활성화 함수로 sigmoid 함수가

많이 사용되었지만, sigmoid 함수는 0부터 1사이의 값을 갖기 때문에 오류 역전과 단계에서 층마다 gradient에 0과 1사이의 작은 값들이 계속 곱해진다. 따라서, 구조가 깊어질수록 gradient가 0에 가까운 값을 가지게 되어 기중치 갱신이 거의 일어나지 않게 된다. 즉, 마지막 layer는 학습이 잘 되지만, 초기 layer로 갈수록 학습이 잘 되지 않는 vanishing gradient 문제가 발생하게 된다. 따라서 제안하는 머신러닝 모델에서는 최근 널리 사용되는 rectified linear unit (ReLU) 함수를 활성화 함수로 사용한다¹⁶⁾. 은닉층과 은닉 노드 수에 따라 모델의 학습 능력이 달라지기 때문에, 반복 실험을 통해 이상적인 은닉층과 은닉노드 수를 결정한다.

3.2.3 출력층

제안하는 모델의 출력은 4가지 빔포밍 조합이므로, 4개의 출력 노드를 가진다. 이때 네 개의 출력 노드는 각각 식 (8)에 정의된 빔포밍 조합들을 나타낸다. 출력 노드의 출력함수로는 최댓값을 더욱 활성화하고 작은 값들을 억제하는 softmax 함수를 사용한다. 모델

은 네 개의 출력 노드 중 최댓값을 가지는 노드의 빔포밍 조합을 출력 값으로 결정한다.

3.2.4 트레이닝 샘플 생성

머신러닝에서 정확한 분류를 위해서는 머신러닝 모델 트레이닝을 위한 데이터베이스 확보가 필수적이다. 따라서 두 유저 MISO 간섭채널에서 임의의 채널 값들을 발생시키고, 전력에 따른 최적의 빔포밍 조합을 구하는 방식으로 샘플을 확보한다. 샘플은 채널 값과 전력을 입력으로, 빔포밍 조합을 출력으로 갖는다. 이때 실제 고려하는 환경을 위해 식 (1)에서 적당한 η 값이 고려되어야 할 것이다.

3.2.5 트레이닝 모델

제안하는 모델의 트레이닝을 위해 아래와 같이 다른 연구들에서 널리 사용되고 있는 교차 엔트로피 함수를 비용함수로 사용한다.

$$e = - \sum_{i=1}^4 (y_i \log_2 o_i + (1 - y_i) \log_2 (1 - o_i)). \quad (10)$$

여기서, y_i 는 샘플 데이터의 i 번째 label을 나타낸다. 만약 i 번째 label이 정답이라면 y_i 는 1의 값을 갖고, $y_{j \neq i}$ 는 모두 0의 값을 가진다. o_i 는 i 번째 출력 노드의 출력 값이다. 교차 엔트로피 함수는 샘플 데이터의 label 값들과 모델의 출력 값들의 확률분포 차이를 측정함으로써 오류를 추정한다.

활성화 함수로 ReLU 함수를 사용할 때 효율적인 가중치 초기화 방법으로 알려진 He initialization을 사용한다^[17]. 학습 알고리즘으로는 root mean square propagation (RMSProp) 알고리즘에 모멘텀을 추가로 적용한 adaptive moment (adam) 알고리즘을 사용하고 초기 학습률은 0.001로 설정한다^[18]. 배치 사이즈는 10,000으로 설정한다. 과소 적합과 과잉 적합 문제를 피하기 위해 연속으로 30번 동안 성능향상이 없으면 학습을 중단하는 조기 멈춤 전략을 사용하였고, 최대 반복 횟수는 3000번으로 설정하였다.

IV. 실험 결과

이 장에서는 반복 실험을 통하여 본 논문에서 제안하는 머신러닝 모델의 이상적인 은닉층과 은닉노드 개수를 결정한다. 그리고 제안한 머신 모델을 이용하여 전력과 채널 상태에 따른 빔포밍 조합을 구하고 직접 구한 최적의 조합과 비교하여 모델의 정확도를 측

정한다. 또한 송신단 전송률 총 합을 구하여 성능을 비교한다.

먼저 식 (1)의 η 를 0.2로 설정하여 실제 고려하는 환경을 모델링 하였다. 학습을 위한 data set은 train set과 validation set으로 나누어 각각 모델 학습과 검증에 사용하였다. 그림 4는 train set과 validation set의 교차 엔트로피 오차를 iteration에 따라 나타낸 것이다. Train cost는 계속 감소하는 반면, validation cost는 과잉적합 문제가 나타나는 것을 확인할 수 있다. 이를 피하기 위하여, validation cost의 증가 여부를 파악하고 조기 멈춤 전략을 사용하였다. 조기 멈춤 전략에 따라 학습이 완료되면, test set을 이용하여 최종 성능을 평가하였다. 최종 성능을 평가하는 방법으로, 10만 개의 test set을 입력하여 정답과 일치하는 비율을 측정하여 모델의 정확도를 구하였다.

과소 적합과 과잉 적합에 빠지지 않는 최적의 모델 구조를 결정하기 위해 그림 5, 6에 각각 은닉층, 은닉노드 수에 따른 머신러닝 모델의 정확도를 나타내었다. 그림 5를 보면, 은닉노드 수에 상관없이 은닉층 수가 3으로 증가할 때까지는 모델의 정확도가 상승하지만 은닉 노드 수가 100일 때, 은닉층 수가 4로 증가하면 과잉적합에 의해 오히려 정확도가 감소한다. 따라서 모델의 이상적인 은닉층 수를 3으로 결정하였다. 또한 그림 6과 같이 은닉층 수를 3으로 고정하였을 때에는 은닉 노드 수가 100일 때 모델의 정확도가 높으므로, 이상적인 은닉 노드 수를 100으로 결정하였다. 그림 7에서는 트레이닝 샘플 수에 따른 제안하는 머신러닝 모델의 정확도를 나타내었다. 쉽게 예상할 수 있듯이 샘플 수와 모델의 정확도는 비례 관계인 것을

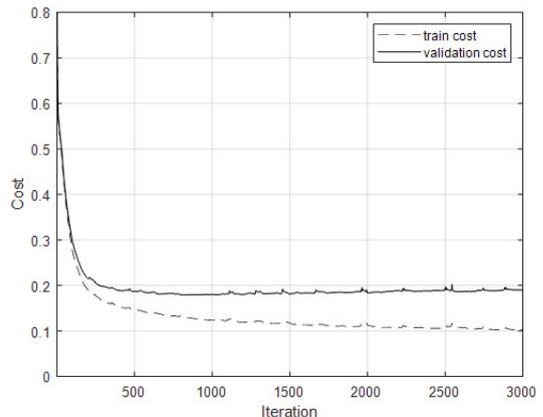


그림 4. 학습횟수에 따른 train set과 validation set의 교차 엔트로피 오차
Fig. 4. The cross-entropy error of train set and validation set according to the iterations

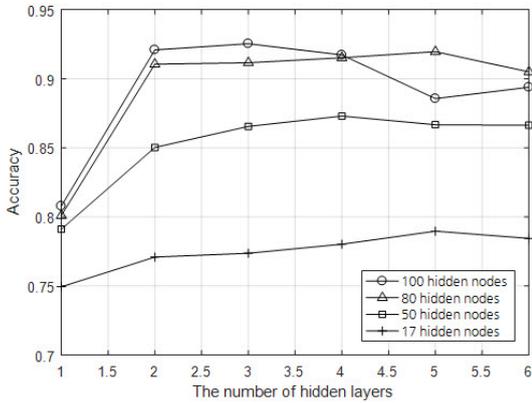


그림 5. 은닉층 수에 따른 모델의 정확도
Fig. 5. The accuracy of the model according to the number of hidden layers

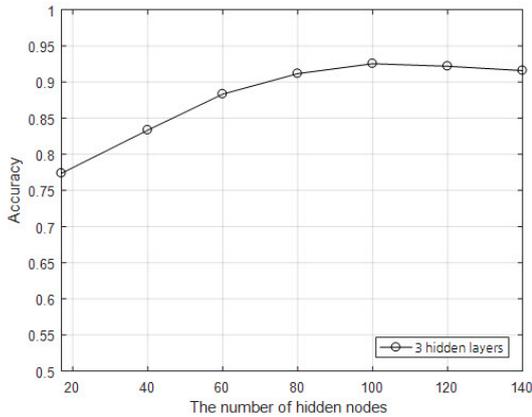


그림 6. 은닉노드 수에 따른 모델의 정확도
Fig. 6. The accuracy of the model according to the number of hidden nodes

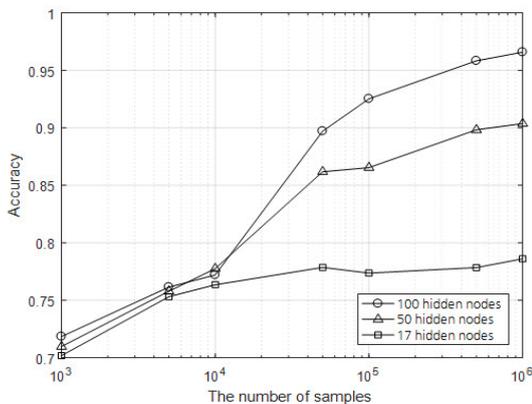


그림 7. 샘플 수에 따른 모델의 정확도
Fig. 7. The accuracy of the model according to the number of samples

확인할 수 있는데, (1만, 5만, 100만) 개의 훈련 샘플을 사용했을 때, 약 (77%, 89%, 96%)의 정확도를 갖는다는 것을 확인할 수 있다.

그림 8은 제안한 머신러닝 모델을 사용한 경우 얻을 수 있는 전송량의 합을 1) 직접 계산한 최적의 빔포밍 조합을 사용한 경우, 2) ZF 빔포밍 벡터만 사용했을 경우, 3) MRT 빔포밍 벡터만 사용했을 경우와 비교한 것이다. 같은 조건에서 성능을 비교하기 위해, 동일한 10만 개의 test set을 사용하였고 전력에 따른 송신단 전송량의 총 합을 평균 내어 나타내었다. 머신러닝 모델을 사용한 경우, 은닉층과 은닉 노드 수는 고정시키고 샘플 데이터 개수만 변경하여 성능을 비교하였다. 그림 9에서는 보다 원활한 성능 비교를 위해 최적의 조합을 사용한 전송량 총 합과 그 외 전송량 총 합의 비율을 나타내

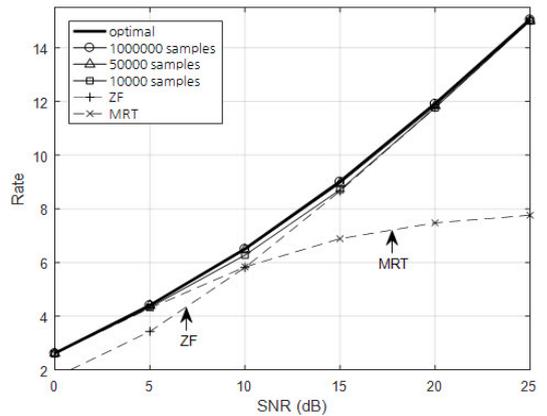


그림 8. 송신기들의 전송량 총 합
Fig. 8. The achievable sum-rate of the transmitters

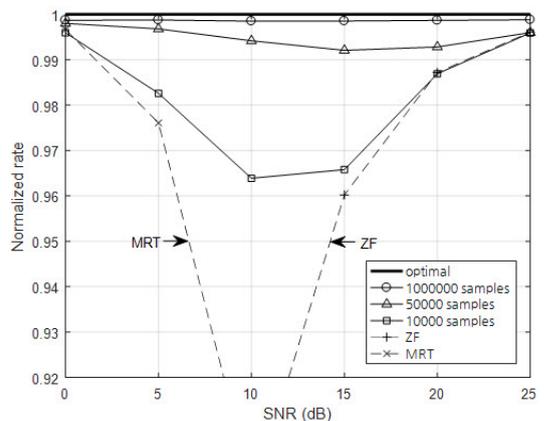


그림 9. 정규화된 전송량 총 합
Fig. 9. A normalized achievable sum-rate

었다. 그림 7에서 모델의 정확도가 낮다고 보여질 수 있으나, 그림 9에서 보면 모델의 100만개의 훈련 샘플을 사용한 경우 (그림 7에서 정확도 96%) 직접 구한 최적의 조합과 거의 유사한 성능을 보이고 만개의 훈련 샘플만 사용하더라도 (그림 7에서 정확도 77%) 특정 빔포밍 벡터 한 가지만 사용하는 것보다는 좋은 성능을 보인다는 것을 알 수 있다.

V. 결 론

본 논문에서는 두 유저 MISO 간섭채널에서 각 유저가 MRT와 ZF 빔포밍 중 하나를 선택하여 사용하는 기법을 머신러닝 모델로 구현하였다. 본 논문에서 구현한 머신러닝 기반 빔포밍 기법이 직접 구한 최적의 조합과 거의 유사한 성능을 보이는 것을 확인하였다. 두 유저 MISO 간섭채널의 경우, 직접 최적의 조합을 구하는 것이 비교적 간단하기 때문에 상대적으로 복잡한 머신러닝 모델을 사용하는 것이 비효율적일 수 있다. 그러나 안테나 수 또는 유저 수가 증가할수록 복잡도가 증가하는 기존의 빔포밍 기법에 비해,^[19] 머신러닝 모델은 초기의 학습 과정 이후부터는 한 차례의 forward propagation만으로 입력에 대한 출력을 구할 수 있다는 장점이 있다. 따라서 향후 두 유저 MISO 간섭채널보다 복잡한 환경에서 머신러닝 모델을 활용할 수 있도록 확장된다면, 변화하는 채널 상태에 따라 매번 모든 경우의 achievable sum-rate를 구하여 최적의 빔포밍 조합을 찾는 것보다 복잡도가 낮을 것이다. 또한, 제한한 머신러닝 기반 빔포밍 기법은 최적의 빔포밍 벡터를 찾는 것은 아니지만, 향후 간섭 채널에서 낮은 복잡도로 최적의 빔포밍 벡터의 성능에 가까운 빔포밍 벡터를 찾을 수 있도록 확장될 것이다.

References

- [1] I. S. Oh, *Machine learning*, Hanbit Academy, Inc., 2017.
- [2] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, and L. D. Jackel, "Backpropagation applied to handwritten zip code recognition," *Neural Computation*, vol. 1, no. 4, pp. 541-551, Dec. 1989.
- [3] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, pp. 436-444, May 2015.
- [4] M. G. Kibria, K. Nguyen, G. P. Villardi, O. Zhao, K. Ishizu, and F. Kojima, "Big data analytics, machine learning, and artificial intelligence in next-generation wireless networks," *IEEE Access*, vol. 6, pp. 32328-32338, May 2018.
- [5] P. Lin and T. Lin, "Machine-learning-based adaptive approach for frame-size optimization in wireless LAN environments," *IEEE Trans. Veh. Technol.*, vol. 58, no. 9, pp. 5060-5073, Nov. 2009.
- [6] P. Geurts, I. E. Khayat, and G. Leduc, "A machine learning approach to improve congestion control over wireless computer networks," *4th IEEE Int. Conf. Data Mining (ICDM'04)*, pp. 383-386, Brighton, UK, Nov. 2004.
- [7] Z. M. Livinsa and S. Jayashri, "Localization with beacon based support vector machine in wireless sensor networks," *2015 Int. Conf. Robotics, Automation, Control and Embedded Systems (RACE)*, pp. 1-4, Chennai, India, Feb. 2015.
- [8] A. Forster, "Machine learning techniques applied to wireless ad-hoc networks: Guide and survey," *2007 3rd Int. Conf. Intell. Sensors, Sensor Netw. and Inf.*, pp. 365-370, Lugano, Switzerland, Dec. 2007.
- [9] U. Challita, L. Dong, and W. Saad, "Proactive resource management for LTE in unlicensed spectrum: A deep learning perspective," *IEEE Trans. Wireless Commun.*, vol. 17, no. 7, pp. 4674-4689, Jul. 2018.
- [10] J. G. Park, G. Y. Kong, and S. Y. Choi, "Machine learning based receiver for MIMO system," *KICS Winter Conf.*, pp. 982-983, Gangwon, Korea, Jan. 2017.
- [11] J. H. Schiller, *Mobile Communications*, Hanbit Academy, Inc., 2016.
- [12] E. A. Jorswieck, E. G. Larsson, and D. Danev, "Complete characterization of the pareto boundary for the MISO interference channel," *IEEE Trans. Signal Process.*, vol. 56, no. 10, pp. 5292-5296, Oct. 2008.

[13] S. A. Jafar and S. Vishwanath, "Generalized degrees of freedom of the symmetric Gaussian K user interference channel," *IEEE Trans. Inf. Theory*, vol. 57, no. 7, pp. 3297-3303, Jul. 2010.

[14] J. Lindblom, E. Karipidis, and E. G. Larsson, "Selfishness and altruism on the MISO interference channel: The case of partial transmitter CSI," *IEEE Commun. Lett.*, vol. 13, no. 9, pp. 667-669, Sep. 2009.

[15] S. Timotheou and G. Zheng, "Beamforming for MISO interference channels with QoS and RF energy transfer," *IEEE Trans. Wireless Commun.*, vol. 13, no. 5, pp. 2646-2658, May 2014.

[16] X. Glorot, A. Bordes, and Y. Bengio, "Deep sparse rectifier neural networks," *14th Int. Conf. on Artificial Intell. and Statistics*, pp. 315-323, Fort Lauderdale, USA, Jun. 2011.

[17] K. He, X. Zhang, S. Ren, and J. Sun, "Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification," *IEEE International Conference on Computer Vision (ICCV 2015)*, pp. 1026-1034, Washington DC, USA, Dec. 2015.

[18] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *3rd International Conference for Learning Representations (ICLR)*, pp. 1-15, San Diego, USA, May 2015.

[19] T. H. Cormen, C. E. Leiserson, R. L. Rivest, and C. Stein, *Introduction to Algorithms*, 3rd Ed., MIT Press, Cambridge, MA, 2009.



권 형 준 (Hyung Jun Kwon)
 2018년 8월 : 한국외국어대학교 공학사
 2018년 8월~현재 : 한국외국어대학교 전자공학과 석사과정
 <관심분야> 이동통신, 머신러닝

이 정 훈 (Jung Hoon Lee)



2006년 6월 : 한국과학기술원 공학사
 2008년 8월 : 한국과학기술원 공학 석사
 2013년 8월 : 한국과학기술원 공학 박사
 2013년 9월~2014년 4월 : 한국과학기술원 박사후연구원
 2014년 8월~2015년 8월 : 미국 노스캐롤라이나 주립대학교 박사후연구원
 2015년 9월~2016년 8월 : 국립제주대학교 전자공학과 조교수
 2016년 9월~현재 : 한국외국어대학교 전자공학과 조교수
 <관심분야> 채널 피드백, 간섭 제어, 무선통신시스템, 머신러닝

최 완 (Wan Choi)



1996년 2월 : 서울대학교 전자공학 공학사
 1998년 2월 : 서울대학교 전자공학 석사
 1998년 2월~2003년 7월 : KT Freetel 과장
 2006년 12월 : University of Texas at Austin, Department of Electrical and Computer Engineering 박사
 2007년~2011년 : 한국과학기술원 (KAIST) 전기 및 전자공학부 교수
 2011년~2017년 : 한국과학기술원 (KAIST) 전기 및 전자공학부 부교수
 2017년~현재 : 한국과학기술원 (KAIST) 전기 및 전자공학부 정교수
 <관심분야> 무선 캐싱 시스템, 모바일 캐싱, 차량간 통신, 밀리미터파 통신