

다중안테나 시스템에서 안테나 수에 대해 확장 가능한 지능형 빔포밍 기법 연구

백승환, 김상민, 이인규
고려대학교 전기전자공학과

{s_baek,smgeem,inkyu}@korea.ac.kr

Deep Learning based Scalable Beamforming Method in MIMO Systems

Seunghwan Baek, Sangmin Kim and Inkyu Lee
School of Electrical Engineering, Korea University

요약

본 논문은 안테나 수에 관계없이 활용가능한 지능형 빔포밍 방법에 대한 연구이다. 지능형 빔포밍 기법들은 다양한 채널 환경에서 채널의 특성을 학습하여 다방면으로 우수한 성능을 나타내고 있다. 하지만, 기존의 지능형 기법들은 안테나 수에 따라 인공 신경망의 입력과 출력의 차원이 결정되기 때문에 안테나 수에 따라 각기 다른 인공 신경망을 필요로 하는 한계점이 있었다. 본 논문에서는 이러한 문제점을 해결하기 위해 graph neural network (GNN) 방식을 사용하여 안테나 수에 대해 확장 가능한 지능형 빔포밍 기법을 제안한다. 또한, 실험 결과를 통해 다양한 안테나 수에서 최적에 가까운 성능을 나타내는 것을 확인한다.

I. 서론

최근 인공지능 기술의 발달로 인해 무선 통신 시스템에서도 deep learning (DL) 알고리즘 개발을 통한 성능 향상 연구들이 수행되고 있다. 특히, 다중안테나 시스템에서 interference management 를 위한 지능형 빔포밍 방식 및 채널 추정 혹은 codebook 기반의 channel state information (CSI) 피드백 과정에서 발생하는 distortion 에 robust 한 지능형 beamforming 방식에 대한 연구가 수행되었다. [1-2] 하지만, 기존의 지능형 기법들은 안테나 수에 따라 인공 신경망의 입력과 출력의 차원이 결정되기 때문에 안테나 수에 따라 각기 다른 인공 신경망을 필요로 하는 한계점이 있었다. 본 논문에서는 이러한 문제점을 해결하기 위해 graph neural network (GNN) 방식을 사용하여 안테나 수에 대해 확장 가능한 지능형 빔포밍 기법을 제안한다. 또한, 실험 결과를 통해 다양한 안테나 수에서 최적에 가까운 성능을 나타내는 것을 확인한다.

II. 시스템 모델

본 논문에서는 알고리즘의 성능을 분석하기 위해 $M \triangleq M_y \times M_x$ 개의 antenna elements 로 구성된 uniform planar array (UPA) 구조의 base station (BS)와 단일 안테나를 보유한 user equipment (UE)가 존재하는 multiple-input single-output (MISO) 시스템을 고려한다. UE 단에서의 수신 신호 y 는 다음과 같다.

$$y = \mathbf{h}^H \mathbf{v} s + n \quad (1)$$

이때, $\mathbf{v} \in \mathbb{C}^{M \times 1}$ 와 $n \sim CN(0, \sigma^2)$ 은 각각 빔포밍 벡터와 노이즈를 의미한다. 또한, $\mathbf{h} \in \mathbb{C}^{M \times 1}$ 은 BS 로부터 UE 로 향하는 하향링크 채널을 의미하며 다음과 같이 모델링 된다.[3]

$$\mathbf{h} = \sum_{l=0}^{L-1} \sum_{p=0}^{P_l-1} \alpha_{l,p} \mathbf{a}_y(\mu_{l,p}) \otimes \mathbf{a}_x(\mu_{l,p}, \nu_{l,p}) \quad (2)$$

이때, L 과 P_l 은 각각 cluster 의 수와 l 번째 cluster 에 포함되는 path 의 수를 의미한다. 또한, $\alpha_{l,p}$ 는 complex channel gain 을 의미하며, steering vector $\mathbf{a}_{X,Y}(\cdot)$ 는 다음과 같이 표현된다.

$$[\mathbf{a}_x(\mu, \nu)]_{m_x} = \frac{1}{\sqrt{M_x}} e^{-j2\pi \frac{d_x}{\lambda} (m_x-1) \sin \mu \cos \nu} \quad (3)$$

$$[\mathbf{a}_y(\mu)]_{m_y} = \frac{1}{\sqrt{M_y}} e^{-j2\pi \frac{d_y}{\lambda} (m_y-1) \cos \mu} \quad (4)$$

이때의 합 전송률 최적화를 위한 지능형 빔포밍 디자인 문제는 다음과 같이 나타낼 수 있다.

$$\begin{aligned} \max_{\theta} \quad & R(\mathbf{v}_\theta) \\ \text{s.t.} \quad & \mathbf{v}_\theta^H \mathbf{v}_\theta = P_T \end{aligned} \quad (5)$$

여기서 P_T 와 \mathbf{v}_θ 는 각각 송신 파워 전력과 neural network (NN)으로 도출한 빔포밍 벡터이며 $R(\mathbf{v}_\theta)$ 은 다음과 같다.

$$R(\mathbf{v}_\theta) = \log_2 \left(1 + \frac{\mathbf{h}^H \mathbf{v}_\theta \mathbf{v}_\theta^H \mathbf{h}}{\sigma^2} \right) \quad (6)$$

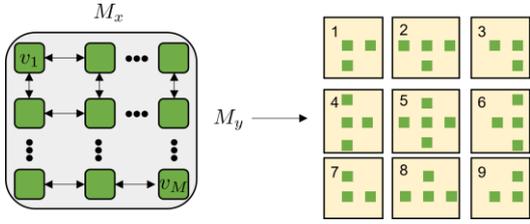


그림 1 UPA 구조 안테나 case decomposition

III. GNN 기반 빔포밍 기법

기존의 DL 기반의 빔포밍 방식 중 가장 대표적인 direct beamforming learning (DBL) 방식은 추정된 채널 정보로부터 빔포밍 벡터 \mathbf{v}_θ 를 도출해내는 방식이다. 하지만, 이러한 방식은 안테나 수에 대해 scalable 하지 못하다는 한계점을 가지고 있다. 이러한 문제점을 극복하기 위해 본 절에서는 \mathbf{v}_θ 를 도출하기 위한 GNN 기반의 빔포밍 벡터 도출 방식에 대해 소개한다.

UPA 안테나 구조를 그래프 모델링하기 위해 그림 1 과 같이 UPA 구조의 안테나에서 발생가능한 case 별로 decomposition 한다. 본 논문에서는 nearest neighbor antenna elements (NNAE) 규칙에 의해 각 안테나 elements 들은 가장 인접한 안테나 elements 들과 연관이 있다고 가정한다. Decomposition 이후 모든 UPA 구조에서의 안테나들은 항상 그림 1 에 나타난 9 개의 case 중 하나의 case 포함된다. 이때, case set 을 $\mathcal{K} = \{1, 2, \dots, 9\}$ 과 같이 정의할 수 있으며, m 번째 안테나의 NNAE set 은 \mathcal{N}_m NNAE 규칙에 의해 결정된다. 최종적으로 \mathbf{v}_θ 의 m 번째 vector element 는 다음과 같다.

$$v_m = \Theta_{f(m)} \left(\bigcup_{n \in \mathcal{N}_m} h_n \right), \forall m \quad (7)$$

여기서 Θ_k 는 k 번째 case 에 대응되는 NN 을 의미하며, $f(m) : m \rightarrow k \in \mathcal{K}$ 함수는 m 이 속하는 case set 의 index 로 대응시키는 mapping function 을 의미한다. 이러한 NN 구조를 학습하기 위해 stochastic gradient descent (SGD)를 이용하며 합 전송률을 최대화하기 위한 업데이트 규칙에 대한 수학적 표현은 다음과 같다.

$$\theta^{(i+1)} \leftarrow \theta^{(i)} + \eta \nabla_{\theta^{(i)}} R(\mathbf{v}_\theta) \quad (8)$$

이때, η 는 learning rate 을 의미한다.

IV. 실험결과

본 절에서는 제안하는 GNN 기반의 빔포밍 기법에 대한 성능 분석을 위해 $\sigma^2 = 1$, $P_T = 20\text{dBm}$, $M_x = M_y = \sqrt{M}$ 의 시스템을 상정한다. 또한, learning rate 은 $\eta = 10^{-4}$ 다음과 같이 설정하며 파라미터 업데이트를 위해 adaptive moment estimation (Adam) optimizer 를 사용한다. 비교 기법으로는 maximum ratio transmission (MRT) 기법을 고려한다. 그림 2 에서 확인할 수 있듯이 제안하는 GNN 방식의 빔포밍 방식은 하나의 NN 모델을 학습하여 송신 안테나 수에 관계없이 MRT 기법에 근사한 성능을 보인다. 기존의 DBL 방식의 경우 송신안테나 수에 따라 각 각에 대응되는 NN 모델을 학습이 필요한 반면 제안하는 GNN

기반의 빔포밍 방식은 안테나 수에 대해 확장 가능하다는 장점이 있다.

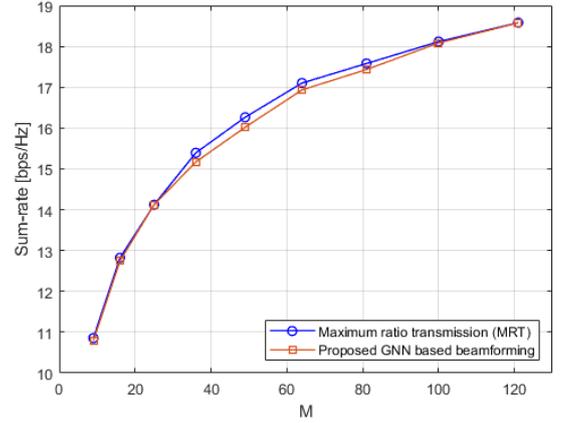


그림 2 안테나 수에 따른 합 전송률 성능 그래프

V. 결론

본 논문에서는 다중안테나 시스템에서 안테나 수에 대해 확장 가능한 지능형 빔포밍 기법을 새롭게 제안하였다. 기존의 지능형 빔포밍 기법들은 여러 채널 환경에서 다방면으로 우수한 성능을 나타내고 있다. 하지만 기존의 방식들은 안테나 수에 대해 확장이 제한되는 한계점이 존재하였다. 본 논문에서는 이를 해결하기 위해 GNN 방식을 통한 새로운 빔포밍 방식을 제안하였고 제안하는 방식이 MISO 상황에서 optimal 성능에 근사한 성능을 나타내는 것을 확인하였다.

ACKNOWLEDGMENT

본 연구는 방위사업청과 국방과학연구소가 지원하는 미래전투체계 네트워크기술 특화연구센터 사업의 일환으로 수행되었습니다. (UD190033ED).

참고 문헌

- [1] J. Guo, C. -K. Wen and S. Jin, "Deep Learning-Based CSI Feedback for Beamforming in Single- and Multi-Cell Massive MIMO Systems," IEEE J. Sel. Areas Commun., vol. 39, no. 7, pp. 1872-1884, Jul. 2021.
- [2] W. Xia, G. Zheng, K. -K. Wong and H. Zhu, "Model-Driven Beamforming Neural Networks," IEEE Wireless Commun., vol. 27, no. 1, pp. 68-75, Feb. 2020.
- [3] A. Wang, R. Yin and C. Zhong, "Channel Estimation for Uniform Rectangular Array Based Massive MIMO Systems with Low Complexity," IEEE Trans. Veh. Technol., vol. 68, no. 3, pp. 2545-2556, Mar. 2019.