

불완전 채널 상태 정보의 그래프 신경망 기반 빔포밍 성능 평가

우우석, 최승기, 이예진, 박호성*

전남대학교 지능전자컴퓨터공학과, *전남대학교 전자컴퓨터공학과

blackvide@jnu.ac.kr, csq05158@naver.com, yetin124@naver.com, *hpark1@jnu.ac.kr

Performance Evaluation of Graph Neuralnet-based Beamforming with Imperfect Channel State Information

Woo Seok Woo, Seunggi Choi, Yejin Lee, Hosung Park*

Chonnam National Univ., *Chonnam National Univ.

요약

본 논문은 다중 사용자 단일 안테나 기지국 다중 안테나(Multi-User Multiple Input Single Output: MU-MISO) 상황에서의 빔포밍을 위하여 기존 대부분의 빔포밍 논문들이 채널 정보를 완벽하게 아는(Channel State information: CSI) 상황에서의 시뮬레이션과 다르게 실제 상황에서 불완전한 채널 정보(Imperfect Channel State Information: ICSI)를 가지고 빔포밍 방식을 통해 ICSI 채널 상황을 학습하여서 기존의 CSI를 기반으로 한 다른 논문들 대비 높은 성능을 보였다.

I. 서론

본 논문에서는 물리 계층에서의 빔포밍을 위한 방법으로 딥러닝을 이용한 논문이다. 빔포밍 기술은 다중 안테나 통신 시스템에서 효과적인 방안으로서 제시되어왔고 또한 최적의 솔루션 역시 존재한다.[1] 그렇지만 실제로 최적의 솔루션을 구하는 것은 시간적으로 오래 걸리는 문제점이 있기에 실시간 통신에서는 무선 통신의 빠르게 변하는 채널 상황에 맞게 최적과 가깝고 빠르게 빔포밍 벡터를 구할 수 있는 알고리즘이 필요하다. 그 중 가장 최소 평균 제곱 오차(Weighted Minimum Mean Squared Error: WMMSE)[2]는 시스템의 데이터 최대화에 대한 지역적인 최적화 솔루션을 제공한다. 하지만 WMMSE 역시 사용자와 기지국 안테나 수에 따라 빔포밍 값을 알아내는 시간이 오래 걸리게 되고 이에 따른 대안 방식으로 많이 제안되는 것이 딥러닝을 통한 빔포밍 학습이다.[3][4]

특히 그래프 신경망(Graph Neural Network: GNN)은 기지국과 사용자 사이의 무선 통신 상황을 잘 나타낼 수 있고[5], 특히 기지국 안테나와 사용자 수에 따른 확장성과 강인함을 보여주는 논문들이 존재한다.[6][7]

하지만 이런 빔포밍 논문들은 채널 상황 정보를 완벽히 암을 가정한다. 그렇기에 실제 무선 통신 상황에서는 부정확한 채널을 기반으로 추정을 하게 되고 이는 성능 저하로 이어지게 된다.

본 논문에서는 이런 ICSI 상황에서의 채널 빔포밍을 가정하여 GNN 기반의 빔포밍을 통한 기존 CSI 기반 빔포밍 대비 좋은 성능을 보이는 빔포밍 기법을 소개한다.

II. 본론

1. 시스템 모델

본 논문에서는 MU-MISO 다운링크 상황을 가정하여서 다음과 같은 MU-MISO 시스템을 가정한다. $\tilde{N} \triangleq \{1, \dots, |\tilde{N}|\}$, $\tilde{K} \triangleq \{1, \dots, |\tilde{K}|\}$ 에서 N 과 K 는 각각 기지국의 안테나와 사용자 수를 나타낸다. 그리고 사용자 k 는 $h_k \in \mathbb{C}^N$ 의 채널 벡터를 겪게 된다. 이때 송신 빔포밍 벡터는 $w_k \in \mathbb{C}^N$ 로 정의한다. 여기서 k 번째 사용자의 신호 대 간섭 및 잡음 비율(Signal-to-interference-plus-noise ratio: SINR)의 사용자 k 에서의 값은 다음과 같다.

$$SINR_k = \frac{|h_k^H w_k|^2}{\sum_{l \in \tilde{K} \setminus k} |h_k^H w_l|^2 + \sigma^2} \quad (1)$$

위의 식에서 σ^2 은 잡음 신호 전력을 나타낸다. 그리고 사용자 k 의 데이터율은 다음과 같다.

$$r_k = \log(1 + SINR_k) \quad (2)$$

본 논문에서는 시스템 모델의 데이터율 합(Sum rate)을 최대화하는 것을 목표로 한다.

$$\begin{aligned} & \text{maximize} \quad \sum_{k \in \tilde{K}} r_k \\ & \text{s.t.} \quad \sum_{k \in \tilde{K}} \|w_k\|^2 \leq P \end{aligned} \quad (3)$$

여기서 P 는 기지국에서 사용 가능한 최대 송신 전력이다. 그리고 본 논문에서는 ICSI 상황을 가정하기에 기지국이 수신하는 채널은 다음과 같다.

$$\hat{h}_k = h_k + e_k \quad (4)$$

여기서 e_k 는 랜덤 변수로 확률분포와 같은 통계적 특징을 가진다. 그리고 기지국은 완벽한 CSI가 아닌 (4)와 같은 채널을 기반으로 빔포밍을 한다.

2. 딥러닝을 통한 ICSI 기반 빔포밍 추정

본 논문에서는 위와 같은 ICSI 상황에 강인한 빔포밍 추론을 딥러닝 모델을 통해 해결하려 한다. 딥러닝의 기본 모델은 GNN 기반의 빔포밍 모델 논문[8]을 참고하였다. GNN 모델은 기지국, 사용자, 빔포밍 전력 결정으로 이루어진 3개의 다층 퍼셉트론(Multi Layer Perceptron: MLP)으로 구성되어 서로에게 사용자와 기지국 사이의 관계를 표현해 정보를 교환하며 추론하는 형태를 가진다. 또한 각각의 MLP의 입력으로 각각이 만들어낸 메시지와 기지국에서 추론된 채널과 추가적으로 오류 채널의 분산을 입력으로 하여 학습을 진행하였다. 또 효과적인 빔포밍을 위해 정규화된 제로포싱(Regularized Zero Forcing: RZF)[1]의 수식인

$$w_k^* = \sqrt{p_k} \frac{I_N + \sum_{i=1}^K q_i h_i h_i^H}{\|I_N + \sum_{i=1}^K q_i h_i h_i^H\|}^{-1} h_k, \quad \forall k \quad (5)$$

를 통해 GNN 모델은 각 사용자에게 할당할 전력인 p_k, q_k 를 추론한다.

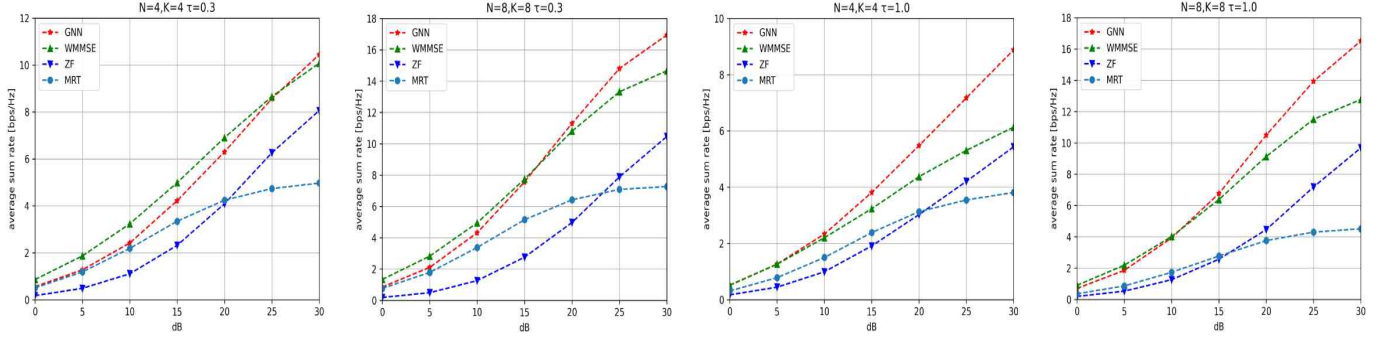


그림 1. $N=K=4$, $N=K=8$ 에서 $\tau=0.3$, 1.0 에서의 평균적인 데이터율 합 비교.

3. 시뮬레이션 설정

본 논문에서는 ICSI 상황을 가정하기에 기지국에 수신하는 채널이 부정확하다. 이는 본 논문에서는 [9]에 나온 채널 오류 방식으로 나타내고 이는 다음과 같이 $e_k \sim CN(0, \epsilon_k I)$, $\epsilon_k = \tau \|h_k\|_2^2$, $\tau \in (0, 1]$ 로 정의한다. 그리고 각 레이어의 구성은 다음 표 1로 요약한다. M 은 사용자가 지정하는 파라미터 개수이다.

표 1. 각 MLP별 레이어 차원 구성

	기지국/사용자	전력 결정
Input	200	200
Dense	200 + ReLu	200 + ReLu
Dense	M + Tanh	2 + Sigmoid

그리고 잡음 신호 전력 $\sigma^2 = 1$ 로 고정하였고 이에 따른 SNR은 전체 전력 대비 잡음 신호 전력인 $\frac{P_{\max}}{\sigma^2}$ 으로 dB를 나타낸다.

추가적으로 모든 레이어에는 레이어 정규화를 사용했다. 학습 시에는 Epoch = 100, Learning rate = 0.0005, Mini batch set = 50, Mini batch size = 1000에 Validation과 Test에 5000개의 채널을 사용했다.

4. 시뮬레이션 결과

본 논문에서는 $(N=4, K=4)$, $(N=8, K=8)$ 의 경우에서 $\tau = (0.3, 1.0)$ 을 고려하였다. 그림 1의 결과를 기반으로 채널 오류가 큰 경우일 때 GNN을 통한 학습이 기존 대비 좋은 결과를 보일 수 있음을 알 수 있다. 특히 WMMSE[2]와 같은 방법이 채널 오류가 큰 경우에 더 안 좋은 성능을 보이는 것을 확인할 수 있는데 이는 WMMSE와 같은 알고리즘이 CSI 기반의 빔포밍 알고리즘이기때 우리의 직관과 어느 정도 일치함을 알 수 있었다.

III. 결론

본 논문에서는 실제 기지국이 수신하는 ICSI 정보에 기반한 GNN 모델을 통한 빔포밍 추론으로 기존의 CSI를 기준으로 만든 빔포밍 모델들과 비교하여 ICSI 상황에서 더 좋은 성능을 보임을 시뮬레이션을 통해 보여 준다. 이는 GNN 모델이 이런 부정확할 수 있는 ICSI의 정보만을 가지고 추론을 통해 모델이 실제로 학습한 결과, 다른 CSI 기반의 빔포밍 방법 대비 좋은 성능을 보이고 이는 채널 부정확성이 커질수록 더 극명하게 나타나는 것을 확인할 수 있었다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 지역진흥혁신인재양성사업(IITP-2024-00156287,

40%)과 (No.RS-2021-II212068, 인공지능 혁신 허브 연구 개발) 및 (No. 2021001016004, 6G/B5G xURLLC를 위한 유연한 신뢰도의 채널코딩)의 연구이자, 교육부와 한국연구재단의 재원으로 지원을 받아 수행된 첨단분야 혁신융합대학사업(차세대통신)의 연구 결과임.

참고 문헌

- [1] E. Björnson, M. Bengtsson and B. Ottersten, "Optimal Multiuser Transmit Beamforming: A Difficult Problem with a Simple Solution Structure [Lecture Notes]," in IEEE Signal Processing Magazine, vol. 31, no. 4, pp. 142-148, July 2014
- [2] S. S. Christensen, R. Agarwal, E. De Carvalho and J. M. Cioffi, "Weighted sum-rate maximization using weighted MMSE for MIMO-BC beamforming design," in IEEE Transactions on Wireless Communications, vol. 7, no. 12, pp. 4792-4799, December 2008
- [3] H. Huang, Y. Peng, J. Yang, W. Xia and G. Gui, "Fast Beamforming Design via Deep Learning," in IEEE Transactions on Vehicular Technology, vol. 69, no. 1, pp. 1065-1069, Jan. 2020
- [4] W. Xia, G. Zheng, Y. Zhu, J. Zhang, J. Wang and A. P. Petropulu, "A Deep Learning Framework for Optimization of MISO Downlink Beamforming," in IEEE Transactions on Communications, vol. 68, no. 3, pp. 1866-1880, March 2020
- [5] Y. Shen, J. Zhang, S. H. Song and K. B. Letaief, "Graph Neural Networks for Wireless Communications: From Theory to Practice," in IEEE Transactions on Wireless Communications, vol. 22, no. 5, pp. 3554-3569, May 2023
- [6] J. Kim, H. Lee, S. -E. Hong and S. -H. Park, "A Bipartite Graph Neural Network Approach for Scalable Beamforming Optimization," in IEEE Transactions on Wireless Communications, vol. 22, no. 1, pp. 333-347, Jan. 2023
- [7] Y. Li, Y. Lu, R. Zhang, B. Ai and Z. Zhong, "Deep Learning for Energy Efficient Beamforming in MU-MISO Networks: A GAT-Based Approach," in IEEE Wireless Communications Letters, vol. 12, no. 7, pp. 1264-1268, July 2023
- [8] J. Kim, H. Lee, S. -E. Hong and S. -H. Park, "A Bipartite Graph Neural Network Approach for Scalable Beamforming Optimization," in IEEE Transactions on Wireless Communications, vol. 22, no. 1, pp. 333-347, Jan. 2023
- [9] J. Kim, H. Lee and S. -H. Park, "Learning Robust Beamforming for MISO Downlink Systems," in IEEE Communications Letters, vol. 25, no. 6, pp. 1916-1920, June 2021