

딥 러닝 기반 Massive MIMO 채널 상태 정보 피드백 연구 동향

김도영, 박지훈, 채승호*

한국공학대학교

{skyswimmer, wlgn54457, shchae}@tukorea.ac.kr

Research Trends on Deep Learning Based Massive MIMO Channel State Information Feedback

Doyeong Kim, Jihoon Park, Seong Ho Chae*

Tech University of Korea

요약

Massive MIMO(Multiple Input Multiple Output)는 데이터 전송 효율 향상 등 다양한 이점을 제공하지만, 이를 위해서는 정확한 CSI(Channel State Information)를 획득하는 것이 반드시 필요하다. 그러나, massive MIMO는 사용하는 안테나 수가 급격히 증가함에 따라, 채널 추정을 위한 CSI 피드백 역시 급격히 증가하는 문제를 가진다. 본 논문에서는 이를 극복하기 위한 다양한 CSI 피드백 기법들을 소개하고 그 한계점을 살펴본다.

I. 서론

정확한 채널 상태 정보(Channel State Information: CSI)의 획득은 통신 시스템의 성능을 결정하는 중요한 요소이다[1],[2]. 많은 수의 송수신 안테나를 활용하여 데이터 전송 효율을 극대화하는 Massive MIMO(Multiple Input Multiple Output)는 5G에서 상용화되었으며, 이를 확장한 Extreme Massive MIMO는 6G의 주요 후보 기술로 주목받고 있다[3],[4]. 기존 MIMO보다 더 많은 수의 안테나 배열을 사용한 massive MIMO는 향상된 주파수 및 에너지 효율, 간섭의 감소 등의 다양한 장점을 가지지만, 이를 얻기 위해서는 정확한 CSI 확보가 필수적이다. 그러나, 안테나 배열 크기 증가에 따른 CSI 피드백 오버헤드(Overhead) 증가 문제가 massive MIMO 통신 성능 결정에 중요한 문제로 대두되었으며, 이러한 오버헤드를 감소시키기 위한 다양한 CSI 피드백 방법들이 연구되었다. 본 논문에서는 다양한 CSI 피드백 기법들을 소개하고 그 한계점을 살펴본다.

II. 코드북 및 압축 센싱 기반 massive CSI 피드백 기법 [5],[6]

코드북(Codebook) 기반의 피드백 기법[5]은 사전에 정의한 코드를 기반으로 정보를 주고받는다. 이러한 방식은 코드북의 인덱스만을 전송하기 때문에 낮은 피드백 오버헤드(Overhead)를 가진다는 장점이 있어 다양한 목적의 통신에서 널리 사용되고 있다. 그러나 massive MIMO와 같이 많은 양의 정보를 전송해야 하는 경우 코드북의 크기가 커지게 되고, 이에 따라 인코더와 디코더에서 코드북의 코드를 탐색하는데 많은 시간과 자원이 투입되어야 하며 코드북을 저장하는 데 사용되는 메모리가 증가하는 한계를 가진다.

다음으로, 압축 센싱(Compress Sensing; CS) 기반의 피드백[6]은 일반적으로 CSI에서 유의미한 값이 전체 정보 중 아주 적은 부분에만 존재한다는 점에 착안하여 일부 정보의 손실을 감수하고 압축률을 높이는 방식이다. 이 방법은 코드북 기반의 피드백과 비교해 같은 양의 주파수 자원으로 더 많은 양의 CSI를 전송할 수 있다는 장점이 있지만, 정보를 압축하는 과정에서 일부 손실을 감안하기 때문에 CSI를 복원하는 과정에서 오차가 발생할 가능성이 있다. 또한, 계산에 소모되는 자원이 증가한다는 단점을 가지며, 채널의 희소성에 기반을 두기 때문에 실제 환경에서 채널이 희소

하지 않은 상황이 발생하였을 때 문제가 발생할 수 있다는 한계를 가진다.

III. 딥 러닝 기반 massive MIMO CSI 피드백 기법 [7]-[12]

딥 러닝을 이용한 피드백은 데이터를 이용하여 학습된 신경망으로 인코더(encoder)에서 CSI를 압축하고 디코더(decoder)에서 이를 수신하여 원래의 CSI로 복원한다. 신경망을 이용하기 때문에 비선형적인 압축이 가능하며 학습하는 데이터의 품질에 따라 압축 센싱 기반의 방법보다 더 높은 압축률과 복원 정확도를 달성할 수 있다는 장점이 있다. 이러한 방법은 신경망의 구조에 따라 정확도와 연산량이 달라지기 때문에 이를 고려한 적절한 설계가 이루어지지 못한다면 성능이 하락할 수 있는 특징을 가진다. 본 절에서는 딥 러닝 기반 CSI 피드백 연구를 복원 정확도 향상과 연산량 감소를 목적으로 한 연구로 구분하여 소개한다.

A. 채널 복원 정확도 향상 연구

딥 러닝 기반 massive MIMO CSI 피드백을 최초로 제안한 연구 [7]에서는 단말에서 2차원의 CSI를 CNN(Convolutional Neural Network)을 이용하여 압축한 뒤 벡터로 변환하여 전송하고, BS에서 이를 다시 행렬의 형태로 변환한 뒤 다시 CNN을 이용하여 압축되기 전의 크기의 CSI로 복원하는 방식을 제안하였다. 기존의 CS를 활용한 최신 기법들과 비교하였을 때 모든 압축률에서 2-3dB의 NMSE가 개선되어 딥러닝을 이용한 CSI 피드백의 유효성을 증명하였으나, 성능에서는 추가적인 연구를 통한 개선의 여지가 있음을 밝혔다.

연구 [7]의 신경망 구조를 개선한 연구 [8]에서는 CNN 커널의 크기를 증가시키고 CSI의 적은 부분만이 의미 있는 값을 가진다는 점에 착안하여 비 균일 양자화를 적용하였다. 또한, 양자화 후 복원된 벡터에서 왜곡을 줄이기 위한 오프셋 네트워크를 이용한 구조를 통해 1/4, 1/16의 압축률에서 [5] 대비 각각 10.01dB, 5.49dB의 NMSE 향상을 달성하였다. 단 해당 과정에서 초당 연산량이 각각 4.47배, 5.90배 증가하였다.

연구 [9]는 앞선 연구 [7], [8]과 동일한 CNN 구조의 인코더를 사용하면서 디코더는 트랜스포머(Transformer) 기반의 multi head attention 구조를 사용하여 디코더가 CSI의 장기적인 의존성을 파악할 수 있도록 함으로

씨 성능 향상을 유도했다. 그 결과 연구 [6] 대비 1/4, 1/16의 압축률에서 각각 5.01dB, 0.86dB의 NMSE 향상을 달성하였으나, 초당 연산량 또한 1.45배, 1.48배 증가하였다.

연구 [10]에서는 유효한 CSI를 오토인코더(Autoencoder)를 사용한 매핑(Mapping)을 통해 기준보다 낮은 차원으로 압축하는 방식을 사용하였다. 연구 [7] 대비 1/4의 압축률에서는 약 8%의 연산량 증가로 3dB 수준의 NMSE 개선이 있었으나 1/16의 압축률에서는 같은 연산량에서 9.6dB의 NMSE 향상이 있어 적은 연산량의 증가만으로 높은 압축률에서 복원 성능을 개선하였다.

B. 채널 압축 및 복원 연산량 감소 연구

일반적으로 실제 시스템에서 단말은 초당 연산 성능 및 소비전력 등이 제한되어 있다는 사실을 고려할 때, 연산량은 중요하게 고려되어야 하는 요소이다.

연구 [11]에서는 CSI 피드백의 성능이 인코더의 성능에 크게 의존하며, 인코더에서의 압축 손실을 줄이는 것이 디코더의 복원 성능에 영향을 끼친다는 사실과 인코더 구조의 고도화는 단말의 연산량을 증가시킨다는 문제를 발생시킨다는 문제를 모두 고려하였다. 이에 따라 단말에서 CSI의 물리적 성질을 이용해 정보를 최대한 보존하면서 경량화된 모델을 설계했다. 이를 위해 인코더에서 CSI를 실수와 허수 부분으로 구분하지 않고 복소수 형태로 신경망에 입력하여 연산량을 줄임과 동시에 신호의 진폭과 위상 간의 물리적 관계를 보존하여 CSI 복원 성능의 향상을 가져왔다. 또한, 신호가 전달되는 경로마다 신호의 위상과 지연시간이 달라 경로의 클러스터들이 각각 다른 해상도를 가지기 때문에 신경망이 해상도가 높은 클러스터에 집중할 수 있도록 디코더에서 attention 구조를 사용했다. 그 결과 1/8, 1/16, 1/32의 압축률에서 연구 [8] 대비 평균적으로 약 2dB의 NMSE 손실이 발생했지만 초당 연산량을 각각 12.8%, 10.8%, 9.8% 수준으로 줄이는 것에 성공했다.

연구 [12]에서는 연산량을 대폭 줄이면서도 피드백 성능을 유지하기 위해 딥러닝 네트워크의 학습을 CSI의 압축과 복원이 아닌 연산 최적화 문제로 재정의하는 접근을 제안하였다. 기존 딥러닝 기반의 CSI 피드백에서는 인코더와 디코더를 하나의 블랙박스로 보고 end-to-end 방식으로 학습을 수행해 왔다. 그러나 [12]에서는 딥러닝을 사용하여 네트워크의 각 구성 요소가 갖는 구조적 특성과 CSI 행렬의 통계적 성질을 분석함으로써 압축률과 NMSE 사이의 균형을 최적화한다. 특히, 인코더 부분의 연산량을 감소시키기 위해 경사 하강법을 사용하지 않고 경량화된 고정 연산을 사용하여 단말의 연산을 단순화시켰고, 디코더에서는 복원 성능을 보완하기 위해 attention 기반 구조를 적용했다. 이와 더불어, CSI의 회소성과 구조적 상관성을 활용한 특화된 손실 함수 설계를 통해 모델이 효율적으로 학습되도록 유도하였다. 시뮬레이션 결과, 다양한 압축률 환경에서 기존 딥러닝을 사용한 SOTA 구조들과 유사한 NMSE를 유지하면서 연구 [8] 대비 연산량을 1/6 수준으로 감소시켰다.

IV. 결론

본 논문에서는 딥러닝 기반 massive MIMO CSI 피드백의 감소에 대한 최신 연구 결과들을 통해, 딥러닝 알고리즘의 CSI 복원 정확도와 연산량의 상충 관계와 최신 연구 동향을 알아보았다. 딥러닝 모델의 고도화로 요구되는 연산량 증가와 단말 및 기지국의 실제 성능을 고려할 때, 압축률 증가에 따른 정보 손실로 인한 정확도 감소는 5G와 더 많은 수의 안테나 배열을 사용하는 6G에서도 중요한 연구 과제로 남아있다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-학·석사연계ICT핵심인재양성의 지원(IITP-2025-RS-2022-00156326, 50%)과 정보통신기획평가원-지역지능화혁신인재양성사업의 지원을 받아 수행된 연구임(IITP-2025-RS-2020-II201741, 50%)

참 고 문 헌

- [1] T. Kim and S. H. Chae, "A channel estimator via non-orthogonal pilot signals for uplink cellular IoT," *IEEE Access*, vol. 7, pp. 53419–53428, Apr. 2019.
- [2] M. J. Kang, S. H. Chae, and J. H. Lee, "Channel estimation with DnCNN in massive MISO LEO satellite systems," in Proc. of the 14th Int. Conf. on Ubiquitous and Future Netw. (ICUFN), Paris, France, Jul. 2023.
- [3] N. Varshney *et al.*, "Adaptive channel-state-information feedback in integrated sensing and communication systems," *IEEE Internet Things J.*, vol. 10, no. 24, pp. 22469–22486, Dec. 2023.
- [4] Z. Wang, J. Zhang, H. Du, D. Niyato, S. Cui, B. Ai, "A tutorial on extremely large-scale MIMO for 6G: Fundamentals, signal processing, and applications," *IEEE Commun. Surveys Tuts.*, vol. 26, no. 3, pp. 1560–1605, third quarter 2024.
- [5] D. J. Love, R. W. Heath, V. K. N. Lau, D. Gesbert, B. D. Rao and M. Andrews, "An overview of limited feedback in wireless communication systems," *IEEE J. Select. Areas Commun.*, vol. 26, no. 8, pp. 1341–1365, Oct. 2008.
- [6] M. E. Eltayeb, T. Y. Al-Naffouri and H. R. Bahrami, "Compressive sensing for feedback reduction in MIMO broadcast channels," *IEEE Trans. Wireless Commun.*, vol. 62, no. 9, pp. 3209–3222, Sep. 2014.
- [7] C. -K. Wen, W. -T. Shih and S. Jin, "Deep learning for massive MIMO CSI feedback," *IEEE Wireless Commun. Lett.*, vol. 7, no. 5, pp. 748–751, Oct. 2018.
- [8] J. Guo, C. -K. Wen, S. Jin and G. Y. Li, "Convolutional neural network-based multiple-rate compressive sensing for massive MIMO CSI feedback: Design, simulation, and analysis," *IEEE Trans. Wireless Commun.*, vol. 19, no. 4, pp. 2827–2840, Apr. 2020.
- [9] Y. Cui, A. Guo and C. Song, "TransNet: Full attention network for CSI feedback in FDD massive MIMO system," *IEEE Wireless Commun. Lett.*, vol. 11, no. 5, pp. 903–907, May 2022.
- [10] Y. Cao, H. Yin, Z. Qin, W. Li, W. Wu and M. Debbah, "A manifold learning-based CSI feedback framework for FDD massive MIMO," *IEEE Trans. Commun.*, vol. 73, no. 3, pp. 1833–1846, Mar. 2025.
- [11] S. Ji and M. Li, "CLNet: complex input lightweight neural network designed for massive MIMO CSI feedback," *IEEE Wireless Commun. Lett.*, vol. 10, no. 10, pp. 2318–2322, Oct. 2021.
- [12] Y. Ma, H. He, S. Song, J. Zhang and K. B. Letaief, "Low-complexity CSI feedback for FDD massive MIMO systems via learning to optimize," *IEEE Trans. Wireless Commun.*, vol. 24, no. 4, pp. 3483–3498, Apr. 2025.