

심층강화학습 기반 상향링크 전력 제어 동향 및
GNN 을 활용한 성능향상 연구 방향

유정엽, 고영채
고려대학교

youj0305@korea.ac.kr, koyc@korea.ac.kr

A Survey on Deep Reinforcement Learning Based Uplink Power Control and
Research with Graph Neural Networks for Performance Enhancement

Jeong-Yeop You, Young-Chai Ko
Korea Univ.

요 약

5 세대 무선 네트워크는 높은 사용자 밀도를 특징으로 하여 높은 통신 트래픽을 가지고, 이는 셀 간 간섭을 유발하여 사용자 단말들의 전력 상승을 유도한다. 이는 상향링크 시스템의 셀 용량, 커버리지, 하향링크 성능의 감소로 이어지게 되어 서비스 품질을 낮추게 된다. 이를 해결하기 위해 다중 에이전트 심층 강화학습 및 그래프 신경망을 기반으로 한 상향링크 전력 제어 방법들이 제안되고 있다. 본 논문에서는 상향링크 전력 제어 문제에 적용될 수 있는 강화학습 기반 및 그래프 신경망 기반 알고리즘을 소개하고, 각 연구의 구조적 특징과 성능을 분석하고 향후 연구 방향을 제시한다.

I. 서 론

다중 셀, 다중 사용자 환경에서 5 세대 무선 네트워크는 높은 사용자 밀도를 특징으로 한다. 그에 따라 통신 트래픽이 급격하게 증가하게 되고, 이는 셀 혼잡으로 이어지게 된다 [1]. 특히 [그림 1]과 같이 상향링크 환경에서 각 셀은 같은 리소스 블록(Resource Block)을 사용할 수 있고, 이는 셀 간 간섭을 유발할 수 있다.

간섭을 겪는 사용자 단말 (UE)은 서비스 품질(QoS)을 보장하기 위해 신호 대 간섭 및 잡음 비(Signal-to-Interference-plus-Noise Ratio, SINR)를 회복하려 전력을 높이고, 이는 또 다시 다른 사용자 단말의 SINR 을 낮추어 상향 링크 셀 용량을 낮추게 된다. 이는 셀의 커버리지와 하향링크 성능 감소로 이어지게 되기 때문에, 상향링크 전력 제어 기술은 무선 통신 네트워크의 핵심적인 설계 문제이다. [2]

상향링크 전력 제어를 위한 방법으로는 전통적인 수학적 접근 및 최적화 방법이 있는데, 현대의 무선 통신 네트워크는 다수의 사용자와 복잡하고 동적인 환경을 특징으로 하기 때문에 최적해를 찾기 어렵다는 한계가 있다. 이를 해결하기 위해 최근에 사용되는 방법 중 하나는 AI 및 ML 을 활용한 전력제어 방법이다. 특히 다중 에이전트 심층 강화학습 방법을 기반으로 한 알고리즘은 상태 정보 및 행동 차원이 고차원인 환경을 신경망으로 근사하여 높은 효율성과 성능을 가지는 장점이 있다. 또한 복수의 에이전트를 활용하여 증가하는 네트워크 규모와 분산된 네트워크 구조에 효과적으로 적용될 수 있다. 또한 그래프 신경망(Graph Neural Network, GNN)을 해당 네트워크 구조의 에이전트에 적용하면, 에이전트 간에 전력, RB 할당 패턴, 간섭의

강도 등을 공유할 수 있다. 본 논문에서는 다중 에이전트 심층 강화학습 및 그래프 신경망을 기반으로 한 상향링크 전력 제어 방법에 대한 연구 동향 및 연구 방향을 살펴본다.




그림 1. 상향링크 셀 간 간섭

II. 본론

상향링크 전력 최적화는 상향링크 스펙트럼 효율 (Spectral Efficiency) 향상시키는 효과적인 기법 중 하나이다. 이를 위해 기존에는 가중 최소평균제곱오차(WMMSE) 방법이나 분수 프로그래밍 (Fractional Programming, FP) 방법과 같은 반복적 알고리즘이 사용되었으나, 계산 복잡도가 높기에 실시간 구현이 어렵다. [3]에서는 이런 문제를 해결하기 위해 데이터 기반 GNN 을 설계하여 채널 행렬로부터 최적 송신 전력으로의 매핑을 학습시켰다. Original-GNN 이라 불리는 데이터 기반 GNN 에 MMSE 수신기 모델을 통합한 MMSE-GNN 모델을 통해 등가 채널 이득 (Equivalent channel gain)을 계산하고, 해당 이득으로부터 송신 전력을 반복적으로 업데이트 하였다. 시뮬레이션 결과, MMSE-GNN 은 5 회 정도의 반복만으로 WMMSE 알고리즘과 유사한 수준의 스펙트럼 효율을 달성하였다. 또한 Original-GNN 과 비교한 결과, 더 높은 스펙트럼효율 및 낮은 학습 복잡도를 가졌으며 우수한 일반화 성능을 보였다.

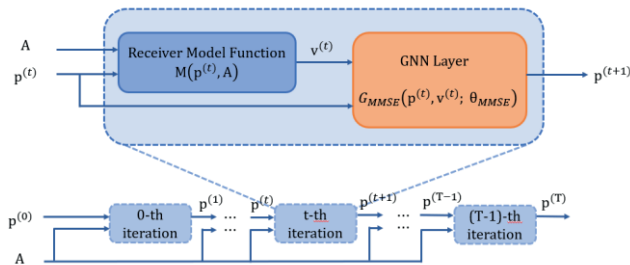


그림 2. MMSE-GNN 구조

[4]에서는 다중 에이전트 강화학습(Multi-Agent Reinforcement Learning, MARL) 환경에서의 비효율적인 정보 공유 문제를 해결하기 위해, 그래프 상호 정보량 (MI, Graphical Mutual Information)을 극대화하는 GNN 기반 통신 학습 구조 (MARGIN)을 제안하였다. 기존의 GNN 기반 MARL 방법은 이웃 에이전트의 정보를 단순히 집계하는 방식으로, 유용한 관계 정보를 충분히 추출하지 못한다는 한계가 있었다. 이를 해결하기 위해 해당 논문에서는 그래프 상호정보량 최적화 기법을 도입하였다. 해당 방법은 이웃 에이전트의 입력 특성과 출력 표현 간의 MI 를 극대화하여, 더 풍부한 표현을 학습하도록 한다. 또한, GNN 과 가치 함수 분해 (Value Decomposition) 및 그래프 MI 최적화의 장점을 통합하여 효율적인 통신 학습 및 정책 학습을 동시에 진행하였다. 시뮬레이션 결과, MARGIN 기법은 QMIX, DGN, G2ANet, MAGIC 등 기존 MARL 기법 대비 높은 보상 및 승률, 더 나은 협력을 보였다. 또한 에이전트 수가 증가하는 대규모 환경에서도 우수한 확장성을 보였다.

III. 결론

본논문에서는 다중 셀, 다중 사용자 환경에서 상향링크 전력 제어를 위한 다중 에이전트 심층 강화학습 및

그래프 신경망 기반 기술에 대한 연구 동향을 조사하였다. 기존의 전통적인 WMMSE, FP 최적화 방식들은 높은 계산 복잡도로 인해 실시간 적용에 한계가 있었다. 이러한 문제점을 해결하기 위해 최근에는 다중 에이전트 심층 강화학습 기법과 그래프 신경망을 기반으로 다양한 방법들이 제시되고 있으며, 해당 방법들은 사용자 단말을 에이전트로 설정하여 효과적으로 협력적인 전력 제어를 학습할 수 있다는 장점이 있다. 본 논문에서는 MMSE 방법을 GNN 에 통합시킨 MMSE-GNN 모델, 다중 에이전트 강화학습 환경에서 에이전트 간 정보 공유 문제를 해결하는 GNN 기반 통신 학습 구조 등이 소개되었다. 이러한 기법들은 기존의 다양한 강화학습 기법과 전력 제어 방식에 비해 더 높은 스펙트럼 효율, 낮은 학습 복잡도, 우수한 일반화 성능을 보였다. 이와 같은 다양한 강화학습 및 그래프 신경망 구조를 상향링크 전력 제어 문제에 적용함으로써, 다수의 사용자와 복잡하고 동적인 환경을 특징으로 하는 현대의 통신 시스템에서 효과적인 전력 제어 기법을 개발할 수 있을 것으로 기대된다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-대학 ICT 연구센터(ITRC)의 지원을 받아 수행된 연구임(RS-2021-II211810)

참 고 문 헌

- [1] F. H. Costa Neto, D. C. Araújo, M. P. Mota, T. F. Maciel and A. L. F. de Almeida, "Uplink Power Control Framework Based on Reinforcement Learning for 5G Networks," in *IEEE Transactions on Vehicular Technology*, vol. 70, no. 6, pp. 5734-5748, June 2021.
- [2] R. Jia *et al.*, "Multi-Agent Deep Reinforcement Learning for Uplink Power Control in Multi-Cell Systems," *2022 IEEE International Conference on Communications Workshops (ICC Workshops)*, Seoul, Korea, Republic of, 2022, pp. 324-330.
- [3] Y. Peng, T. Liu and C. Yang, "Learning Uplink Power Control with MMSE Receiver-based Graph Neural Network," *2023 International Conference on Wireless Communications and Signal Processing (WCSP)*, Hangzhou, China, 2023, pp. 134-139.
- [4] S. Ding, W. Du, L. Ding, J. Zhang, L. Guo and B. An, "Multiagent Reinforcement Learning with Graphical Mutual Information Maximization," in *IEEE Transactions on Neural Networks and Learning Systems*.