

오픈랜 자원 최적화를 위한 그래프 신경망 기법 연구 동향

박희재, 위성률, 송승엽, 이예린, 박래혁

서울과학기술대학교

{prkhj98, holylaw, sysong, 21101146, lhpark}@seoultech.ac.kr

Recent Research on Graph Neural Network for Open RAN Resource Optimization

Heejae Park, Seongryool Wee, Seungyeop Song, Yerin Lee, Laihyuk Park

Seoul National Univ. of Science and Technology

요약

오픈랜은 (O-RAN) 각 구성 요소가 분산되어 있는 구조적 특성으로 인해, 이들 간 실시간 자원 최적화와 협력적 제어가 요구된다. 이러한 구조를 정밀하게 모델링하기 위해 그래프 신경망 (GNN) 이 주목받고 있으며, 본 논문은 O-RAN 환경에서 GNN을 활용한 자원 최적화 연구 동향을 정리하였다.

I. 서론

최근, 다양한 벤더의 장비 간 상호운용성을 보장하는 오픈랜 (Open Radio Access Network, O-RAN) 은 기존 폐쇄형 RAN 구조의 한계를 극복할 수 있는 대안으로 주목받고 있다 [1]. O-RAN은 O-CU (O-RAN Centralized Units), O-DU (O-RAN Distributed Units), O-RU (O-RAN Radio Units), RAN Intelligent Controller (RIC) 등으로 구성되며, 각 구성 요소는 네트워크 성능을 최대화하기 위해 실시간으로 자원을 최적화하고 협력적인 의사결정을 수행해야 한다.

따라서 각 구성 요소 간 상호작용을 효과적으로 반영하고 지능적인 자원 제어를 위해 최근 그래프 신경망 (GNN: Graph Neural Network) 이 핵심 기술로 부상하고 있다 [2]. GNN은 네트워크를 그래프 형태로 모델링함으로써, 각 노드 간의 상호작용과 관계를 학습하고, 분산된 정보 기반의 지능형 제어를 가능하게 한다. 특히, 국지적인 상태 정보만을 이용해도 이웃 노드의 영향을 고려할 수 있어, xApp 충돌 완화, 트래픽 예측, 간섭 관리 등 다양한 제어 문제에 효과적으로 적용 가능하다. 본 논문에서는 O-RAN 환경에서 GNN 기법이 적용된 최근 연구들을 정리하였다.

II. GNN 기반 O-RAN 자원 최적화 연구 동향

연구 [3]에서는 이기종 디바이스와 다양한 서비스가 공존하는 상황에서 연산 지연, 에너지 제약, 모델 수렴 불균형 등으로 인해 발생하는 연합학습 성능 저하를 최소화하는 연구를 진행했다. 이를 위해 저자들은 GNN과 강화학습을 결합한 AutoFedGDRL (Autonomous Real-Time Federated Learning Management with GNN-DRL) 프레임워크를 제안하였다.

AutoFedGDRL은 먼저 GNN을 사용하여 네트워크 내 사용자, 엣지 서버, 글로벌 서버 간의 관계를 그래프로 표현하고, 이를 강화학습에 활용한다. 이후 DDQN (Double Deep Q-Network) 기반의 강화학습 에이전트가 정책을 학습하며, 로컬 학습과 엣지 학습 간 선택, 자원 할당, 서비스 우선 순위 결정, 집계 스케줄링 등 다양한 행동 변수를 최적화한다. 이 과정에서 고려되는 최적화 변수는 학습 지연 시간, 에너지 소비량, 가용 자원량,

서비스별 수렴 상태이며, 각 변수에 대한 보상 값을 통해 총합 보상이 계산된다.

연구 [4]는 O-RAN에서 사용자 단말의 연결 관리를 수행하기 위한 GNN 기반 xApp을 설계하고, 이를 통해 셀 간 부하 불균형 문제와 네트워크 커버리지 저하 문제 해결을 목표로 하였다. 저자들은 전체 네트워크를 그래프 형태로 모델링하고, 셀과 사용자 단말을 각각 노드로, 무선 연결 품질을 엣지로 표현하여, 연결 구조를 최적화하는 문제를 정의하였다. 정의한 문제에서는 세 가지 성능 지표 (네트워크 총 처리량, 셀 엣지 사용자의 커버리지 비율, 자원 할당의 공정성을 나타내는 Jain's Index 기반 부하 균형) 을 고려하였다.

문제를 해결하기 위해 GNN과 강화학습을 결합한 프레임워크를 제안하였다. GNN은 상태-행동 쌍에 대한 유틸리티 점수를 출력하고, 강화학습은 해당 점수를 입력으로 활용하여 사용자 단말의 최적 셀을 순차적으로 결정한다.

연구 [5]의 저자들은 O-RAN의 Near-Real-Time RIC에서 실행되는 xApp 간의 충돌 문제를 해결하기 위해, 제어 파라미터와 네트워크 성능 지표 간의 관계를 학습하고 충돌 그래프를 재구성하는 방법을 제안한다. xApp들은 주파수 자원, 전송 전력, 안테나 기울기 등 다양한 제어 파라미터를 조작하여 각자의 목적 (예: 처리량 최대화, 에너지 절감 등) 을 달성하고자 하지만, 이 과정에서 같은 자원에 대해 상반된 명령을 내릴 경우 성능 저하나 불안정성이 발생할 수 있다.

저자들은 충돌 그래프 재구성을 위해 GNN 기반 모델 제안하였다. GraphSAGE (Graph Sample and aggregate)를 활용하여 xApp, 제어 파라미터, 성능 지표로 구성된 그래프에서 노드 간 관계를 학습하고, 수집된 데이터를 통해 충돌 그래프를 재구성한다. 해당 모델을 통해 직접적, 간접적, 암시적 충돌을 자동으로 탐지한다.

연구 [6]의 저자들은 O-RAN에서 사용자 이동성 관리를 개선하기 위해 GNN 기반 링크 예측 모델을 제안한다. 기존 핸드오버 (HO: Handover) 방식은 수신 신호 세기 기반의 반응형 (Reaction-based) 방식으로 인해 자원 낭비와 지연이 발생하는 문제가 있다. 이에 해당 연구는 HO 최적화

를 위한 핵심 자원으로 무선 연결 자원 (사용자 - 셀 간 링크) 을 정의하고, 이를 사전에 예측하여 최적의 타겟 셀을 결정함으로써 HO 타이밍을 개선하고 신호 오버헤드를 줄이는 것을 목표로 한다.

저자들은 사용자와 셀 간 관계를 그래프로 모델링하고, 이를 GNN 기반 링크 예측 문제로 수식화하였다. Autoencoder 기반 모델과 Subgraph 기반 모델을 비교 분석하며, 실제 셀룰러 데이터셋을 통해 학습 효율성과 예측 정확도를 평가하였다. Autoencoder 방식은 대규모 데이터셋에서도 빠른 학습 속도와 높은 재현율, 평균 정밀도 등에서 우수한 성능을 보였으며, 일반화 측면에서도 강점을 나타냈다. 반면 Subgraph 기반 모델은 소규모 환경에서 정밀도 측면에서 더 뛰어났지만, 연산 비용이 높고 확장성에 한계가 있음을 보였다.

연구 [7]은 O-RAN 환경에서 사용자 QoS (Quality of Service) 를 보장하기 위한 부하 분산 문제를 다룬다. 특히, Guaranteed Bit Rate (GBR) 트래픽과 Best Effort (BE) 트래픽이 혼재된 현실적인 멀티밴드 네트워크에서, 셀 과부하를 방지하고 자원을 효율적으로 분산시키는 것을 목표로 한다. 이를 위해 최적화 대상으로 무선 자원 할당율, 사용자 QoS 만족도, BE 사용자 커버리지를 고려하며, GBR 사용자에게는 최소 전송률 보장을, BE 사용자에게는 셀 가장자리 커버리지 개선을 목표로 한다.

이를 위해 GNN 기반 DQN (Deep Q Network) 알고리즘을 제안하였다. 그래프의 노드는 사용자와 셀로 구성되며, 엣지는 무선 연결과 셀 간 관계를 반영한다. 강화학습을 위한 상태는 사용자 및 셀의 SINR (Signal-to-Interference-plus-Noise-Ratio), 데이터 속도, 대역폭 등으로 구성되고, 행동은 사용자의 연결 셀 변경으로 설정하였다. 보상은 QoS 만족도 향상 및 BE 커버리지 증가량으로 정의하였다.

III. 결 론

본 논문은 O-RAN 환경을 위한 GNN 기반 자원 최적화 연구 동향을 조사하였다. 기존 연구들은 대부분 강화학습과 결합하여 자원 최적화 문제를 해결하고 있음을 볼 수 있다. 향후에는 Meta-Learning과 같은 강화학습 이외의 알고리즘을 GNN에 접목한 연구를 분석할 예정이다.

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터 육성지원사업의 연구결과로 수행되었음 (IITP-2025-RS-2022-00156353)

참 고 문 헌

- [1] B. Agarwal, R. Irmer, D. Lister and G. -M. Muntean, "Open RAN for 6G Networks: Architecture, Use Cases and Open Issues," in IEEE Communications Surveys & Tutorials.
- [2] Y. Dai et al., "A Survey of Graph-Based Resource Management in Wireless Networks -Part II: Learning Approaches," in IEEE Transactions on Cognitive Communications and Networking.
- [3] P. Tam and S. Kim, "Graph-Based Learning in Core and Edge Virtualized O-RAN for Handling Real-Time AI Workloads," in IEEE Transactions on Network Science and Engineering, vol. 12, no. 1, pp. 302-318, Jan.-Feb. 2025.
- [4] O. Orhan, V. N. Swamy, T. Tetzlaff, M. Nassar, H. Nikopour and S. Talwar, "Connection Management xAPP for O-RAN RIC: A Graph Neural Network and Reinforcement Learning Approach," 2021

20th IEEE International Conference on Machine Learning and Applications (ICMLA), Pasadena, CA, USA, 2021, pp. 936-941.

- [5] A. Zolghadr, J. F. Santos, L. A. DaSilva and J. Kibilda, "Learning and Reconstructing Conflicts in O-RAN: A Graph Neural Network Approach," 2025 IEEE Wireless Communications and Networking Conference (WCNC), Milan, Italy, 2025.
- [6] A. G.Bermudez, M. Farreras, M. Groshev, J. A. Trujillo, I. de la Banda, and R. Barco. "Graph Neural Networks for O-RAN Mobility Management A Link Prediction Approach," arXiv preprint 2025.
- [7] O. Semiari, H. Nikopour, and S. Talwar, "Graph Reinforcement Learning for QoS-Aware Load Balancing in Open Radio Access Networks," arXiv preprint 2025.