

O-RAN 기반 자원 할당 기술의 최신 연구 동향: 아키텍처, 알고리즘 및 연구 과제

김재민, 원동욱, 오준석, 송치현, 이승찬, 조성래

중앙대학교 컴퓨터공학과

{jmkim, dwwon, jssoh, chsong, sclee}@uclab.re.kr, srcho@cau.ac.kr

Recent Advances in Resource Allocation Techniques for O-RAN: Architectures, Algorithms, and Challenges

Jaemin Kim, Dongwook Won, Junsuk Oh, Chihyun Song, Seungchan Lee, and Sungrae Cho

Department of Computer Science and Engineering, Chung-Ang University

요약

본 논문은 최근 급격히 발전하고 있는 개방형 무선 접속망(O-RAN)의 자원 할당 기술을 다룬다. 기존 RAN 시스템의 폐쇄성과 비효율성을 극복하기 위해 도입된 O-RAN은 개방형 인터페이스와 지능형 제어 구조(RIC)를 바탕으로 자원 활용의 유연성과 자동화를 추구한다. 최근에는 인공지능 및 강화 학습(DRL), 엣지 컴퓨팅(MEC), 네트워크 슬라이싱 기술이 자원 할당에 적극 활용되고 있다. 무선 자원에서는 DRL을 이용한 사용자 연결 및 주파수 제어, 컴퓨팅 자원에서는 O-Cloud 기반 분산 처리와 예측 기반 부하 분산, 네트워크 자원에서는 SDN 기반 슬라이싱과 지역 민감 서비스 대응 기법들에 대해 논의한다.

I. 서론

최근 개방형 무선 접속망(Open Radio Access Networks, O-RAN)의 등장과 발전은 기존 폐쇄적이고 공급자 중심의 무선 접속망(RAN) 구조에서 개방적이고 유연한 구조로의 변화를 촉진하고 있다. 기존 RAN 시스템은 단일 벤더 종속성과 제한적인 인터페이스 구조로 인해 자원 할당의 최적화가 어렵고, 네트워크의 확장성과 혁신 속도에 한계를 드러내왔다. 이에 반해 O-RAN은 표준화된 개방형 인터페이스를 채택하고, 지능형 컨트롤러(RIC)와 엣지 인프라(O-Cloud)를 통해 자원의 동적 제어가 가능하도록 설계되었다[1].

O-RAN 환경에서의 자원 할당 기술은 무선 자원(Radio Resource), 컴퓨팅 자원(Computing Resource), 그리고 네트워크 자원(Network Resource)으로 구분되며, 각각이 서비스 품질(QoS), 지역 민감도(URLLC), 처리 효율성, 슬라이싱 정책 등 다양한 요구사항에 따라 정교하게 관리되어야 한다. 특히 최근에는 인공지능(AI) 및 강화학습(DRL), 엣지 컴퓨팅 기반 예측 분석, 그리고 네트워크 슬라이싱과 연계된 최적화 기법들이 O-RAN 자원 할당에 적극 활용되고 있다.

본 논문은 O-RAN 기반 자원 할당 기술의 최근 연구 방향과 접근 방식을 분류하고, 이를 무선, 컴퓨팅, 네트워크 자원 할당의 관점에서 체계적으로 조망한다. 무선 자원 할당에서는 DRL 기반 사용자 연결 및 주파수 스케줄링 기법을, 컴퓨팅 자원 할당에서는 MEC와 O-Cloud 상의 분산 처리 및 예측 기반 자원 배분 기술을, 네트워크 자원 할당에서는 SDN 및 RIC 기반 슬라이싱 자원 최적화 사례들을 중심으로 논의한다. 본 논문은 이들 기술적 흐름을 분석하여 현재의 성과와 한계, 그리고 향후 연구 방향을 종합적으로 조망하고자 한다.

II. 본론

무선 자원 할당 기술은 효율적인 주파수, 시간 슬롯 및 빔포밍을 통해

자원 활용도를 극대화하는 기술을 포함한다. Mehdaoui 등은 두 가지 심층 강화학습(DRL) 기법을 비교하여 O-RAN의 무선 자원 할당에 적용하였다[2]. 지역 민감 서비스의 QoS 보장을 위해 근실시간 RIC에서 on-policy 알고리즘(PPO)과 off-policy 알고리즘(ACER)을 활용한 결과, 두 기법 모두 기존의 그리디 방식 대비 우수한 성능을 보였으며, PPO는 지역-에너지 균형 측면에서 유리하고 ACER는 수렴 속도가 빠름을 확인하였다. 이는 지능형 RIC 기반 스케줄링에 강화학습을 활용하여 무선 자원 효율을 향상시킨 사례이다. 또한, Yun 등은 다중 무인항공기(UAV)의 협력적 제어를 위한 심층 강화학습 기법을 활용하여 무선 자원 활용 효율성을 높이는 방법을 제시하였다[3].

컴퓨팅 자원 할당 기술은 O-RAN의 가상화된 O-Cloud 인프라에서 에너지 효율적이고 공정한 컴퓨팅 자원 할당을 다룬다. Aslan 등은 실증 실험을 통해 O-Cloud 서버의 하드웨어 성능, 용량, 트래픽 부하에 따른 에너지 소모 특성을 분석하고, 이를 바탕으로 두 가지 정책을 제안했다[4]. “컴퓨팅 자원 할당 정책”은 기지국의 처리 부하를 여러 O-Cloud 서버에 에너지 효율적으로 분산시키고, “무선 자원 제어 정책”은 사용자별 최소 전송 블록 크기를 실시간으로 결정하여 불필요한 전력 소모를 줄이는 기법이다. 제안된 정책들은 온라인 러닝을 통해 시간에 따른 불확실한 변화에 적응하며 장기적 공정성을 보장하고, 시뮬레이션 및 O-RAN 테스트베드 구현을 통해 에너지 절감과 성능 향상을 실증하였다. Filali 등은 초저 지연 통신을 위해 O-RAN에서 통신 자원과 컴퓨팅 자원을 통합적으로 슬라이싱하는 심층 강화학습 기법을 제시하였다[5]. 두 단계로 구성된 RAN slicing 프레임워크를 도입하여, 1단계에서 무선 통신 자원 할당, 2단계에서 엣지 컴퓨팅 자원 할당 문제를 각각 MDP로 모델링하고 단일 에이전트 DRL 알고리즘으로 최적화하였다. 시뮬레이션 결과 제안 기법이 URLLC 서비스의 엄격한 지연 요구사항을 만족하면서 자원을 효율적으로 분배함을 보였다. 이는 MEC와 O-RAN의 결합을 통해 무선 및 계산자원의 교차 최적화가 가능함을 보여준다. 한편, Park 등은 자율 드론 배송 시스템에서

협력적 이동성 제어를 통해 MEC 환경의 효율적 컴퓨팅 자원 할당을 실현하는 학습 기반 접근법을 제안하였다[6].

네트워크 자원 할당은 주로 네트워크 슬라이싱을 중심으로 이루어진다. Firouzi와 Rahmani은 5G O-RAN 기반의 IoT 환경에서 eMBB와 URLLC 서비스의 동시 지원을 위한 자원 할당 기법을 제안하였다[7]. 단일 RAN 인프라상에서 이기종 사물인터넷 트래픽을 수용하기 위해 2단계 네트워크 슬라이싱 메커니즘을 도입하였으며, 서로 다른 지역 요구를 갖는 서비스들을 분리하여 자원을 배정함으로써 IoT 시스템의 지역 민감도에 대응한다. 제안 기법은 O-RAN의 개방형 RIC를 활용한 자동화된 슬라이스 자원 조정을 통해 초고속 및 초저지연 IoT 애플리케이션의 서비스 품질을 향상하였다. Yun 등은 커넥티드 차량 인프라 환경에서 품질 인식 형 딥 강화학습 기술을 이용하여 동적인 네트워크 자원 할당 문제를 효과적으로 해결하였다[8].

III. 결론

본 논문은 O-RAN 환경에서의 자원 할당 기술을 무선, 컴퓨팅, 네트워크 자원으로 구분하여 체계적으로 정리하고, 최근 실제 학술 논문들에 기반한 연구 동향을 살펴보았다. 무선 자원 분야에서는 DRL 기반 강화학습 기법들이 near-RT RIC의 지능형 제어를 통해 사용자 연결성과 자원 스케줄링을 개선하고 있으며, 컴퓨팅 자원에서는 MEC 및 O-Cloud 가상화 자원에 대한 예측 기반 부하 분산과 에너지 효율 최적화가 주요 화두로 다뤄지고 있다. 또한 네트워크 자원 할당 영역에서는 서비스 특성에 따른 네트워크 슬라이싱 기반 자원 분배와 SDN/RIC을 활용한 자율 제어가 활발히 연구되고 있음을 확인하였다.

이와 같은 기술적 진전에도 불구하고, O-RAN의 실시간성 요구와 상호 운용성 확보, 보안 및 개인정보 보호 등의 이슈는 여전히 해결되지 않은 도전 과제로 남아 있다. 향후 연구는 DRL과 연합학습을 기반으로 한 지속적인 학습 프레임워크 설계, 엣지-클라우드 간 연계 최적화, 그리고 슬라이스 간 자원 충돌 회피 정책 개발 등으로 나아갈 필요가 있다. 궁극적으로는 O-RAN 구조의 자율성과 효율성을 동시에 달성할 수 있는 다계층 지능형 자원 할당 프레임워크가 요구된다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-대학ICT연구센터(ITRC)의 지원을 받아 수행된 연구임(IITP-2025-RS-2022-00156353, 50% / IITP-2025-RS-2023-00258639, 50%)

참 고 문 헌

- [1] Polese, Michele, et al. "Understanding O-RAN: Architecture, interfaces, algorithms, security, and research challenges." IEEE Communications Surveys & Tutorials 25.2 (2023): 1376–1411.
- [2] Mehdaoui, Manal, and Amine Abouaomar. "Dynamics of Resource Allocation in O-RANs: An In-depth Exploration of On-Policy and Off-Policy Deep Reinforcement Learning for Real-Time Applications." arXiv preprint arXiv:2412.01839 (2024).
- [3] Yun, Won Joon, et al. "Cooperative multiagent deep reinforcement learning for reliable surveillance via autonomous multi-UAV control." IEEE Transactions on Industrial Informatics 18.10 (2022): 7086–7096.
- [4] Aslan, Fatih, et al. "Fair resource allocation in virtualized o-ran platforms." Proceedings of the ACM on Measurement and Analysis of Computing Systems 8.1 (2024): 1–34.
- [5] Filali, Abderrahime, et al. "Communication and computation O-RAN resource slicing for URLLC services using deep reinforcement learning." IEEE Communications Standards Magazine 7.1 (2023): 66–73.
- [6] Park, Soohyun, Chanyoung Park, and Joongheon Kim. "Learning-based cooperative mobility control for autonomous drone-delivery." IEEE Transactions on Vehicular Technology 73.4 (2023): 4870–4885.
- [7] Firouzi, Ramin, and Rahim Rahmani. "Delay-sensitive resource allocation for IoT systems in 5G O-RAN networks." Internet of Things 26 (2024): 101131.
- [8] Yun, Won Joon, et al. "Quality-aware deep reinforcement learning for streaming in infrastructure-assisted connected vehicles." IEEE Transactions on Vehicular Technology 71.2 (2021): 2002–2017.