

SLA 보장을 위한 지능형 네트워크 슬라이싱 기법 기술 동향

최성진, 이동현, 오준석, 김재민, 이승찬, 김주영, 조성래

중앙대학교

{sjchoi, dhlee, jsch, jmkim, sclee, jykim}@uclab.re.kr, srcho@cau.ac.kr

A Survey on Intelligent Network Slicing Techniques for SLA Assurance

Seongjin Choi, Donghyun Lee, Junsuk Oh, Jaemin Kim, Seungchan Lee,

Juyoung Kim, and Sungrae Cho

Department of Computer Science and Engineering, Chung-Ang University

요약

본 논문은 SLA 보장을 목표로 하는 지능형 RAN 슬라이싱 기법의 기술 동향을 분석하고, 강화학습 및 연합학습 기반 접근법으로 분류하여 비교한다. 이를 통해 대규모 및 동적 슬라이싱 환경에서의 확장성, 안정성, 그리고 SLA 인지형 자원 제어의 핵심 과제를 논의한다.

I. 서론

5G 및 6G 이동통신 네트워크는 eMBB, URLLC, mMTC와 같이 다양한 서비스 요구사항을 동시에 수용하는 방향으로 진화하고 있다. 이에 따라 네트워크에서 서로 다른 QoS (Quality of Service) 를 보장하기 위한 네트워크 슬라이싱이 핵심 기술로 부상하고 있다. 특히 RAN (Radio Access Network) 슬라이싱은 무선 자원의 회소성과 서비스별 QoS 및 QoE (Quality of Experience) 민감도와 밀접한 영향이 있는 기술로, SLA (Service Level Agreement) 를 만족시키는 것이 네트워크 운영의 핵심 과제로 자리 잡고 있다 [1].

그러나 RAN 슬라이싱 환경에서는 사용자 이동성, 트래픽 변동성, 무선 채널의 변동성으로 인해 슬라이스별 요구 자원을 정확히 예측하거나 고정 할당하는 방식에는 한계가 존재한다. 이는 슬라이스 수와 서비스 다양성이 증가할수록 더욱 심화되며, 특히 SLA 위반이 지연이나 신뢰도 저하로 직결되는 서비스에서는 심각한 성능 저하를 초래할 수 있다 [2]. 이로 인해 기존의 규칙 기반 또는 휴리스틱 기반 자원 할당 방식으로는 동적 환경에서 SLA 보장이 어렵다는 점이 지적되고 있다.

이러한 배경에서 최근 연구들은 강화학습(Reinforcement Learning, RL) 기반 기법을 RAN 슬라이싱 제어에 적극적으로 도입하고 있다. RL은 RAN 슬라이싱 문제를 마르코프 결정 과정으로 모델링하여 네트워크 상태 변화에 따라 슬라이스별 자원 할당 정책을 온라인으로 학습할 수 있는 장점을 가진다. 이기종 서비스가 공존하는 시나리오에서 RL을 활용해 슬라이스별 QoS 요구를 동시에 만족시키려는 연구들이 보고되었으며 [3], 중앙집중형 및 분산형 RL 구조를 통해 복잡한 차세대 네트워크 환경에서도 SLA 만족도를 향상시키려는 시도도 이루어지고 있다 [4]. 또한 학습 기반 자원 제어 기법은 RAN 슬라이싱 뿐 아니라 차량 통신, 자율 네트워크 시스템 등 다양한 네트워크 환경에서 의사결정을 위해 사용되고 있다 [5], [6].

한편, 대규모 네트워크에서 중앙집중형 학습이 초래하는 신호 교환 오버헤드와 확장성 문제를 해결하기 위해 연합학습(Federated Learning, FL) 기반 RAN 슬라이싱 제어 또한 주목받고 있다. FL은 각 RAN 엣지 노드가 로컬 데이터를 기반으로 모델을 학습하고 파라미터만을 집계함으로써,

보안 문제를 해결하면서 SLA 인지형 자원 제어를 가능하게 한다. 특히 SLA 위반 확률을 학습 목표에 반영하거나 비IID 환경에서도 안정적인 수렴을 달성하기 위한 확률적 FL 정책이 제안되며, 6G 네트워크 슬라이싱을 위한 유망한 접근법으로 논의되고 있다 [7].

II. 본론

II-1. 단일 에이전트 기반 RL RAN 슬라이싱 기법

초기 지능형 RAN 슬라이싱 연구들은 RAN 전체를 하나의 의사결정 환경으로 모델링하고 단일 강화학습 에이전트가 슬라이스별 무선 자원 할당을 결정하는 구조를 사용했다. 이러한 접근법은 RAN 슬라이싱 문제를 마르코프 결정 과정으로 공식화함으로 트래픽 변동성과 무선 채널의 불확실성을 고려한 적응적 자원 제어를 가능하게 한다.

[3]은 UL/DL decoupling 구조 하에서 DRL 기반 RAN 슬라이싱 기법으로 eMBB와 URLLC 슬라이스 간 충돌하는 지연 및 처리율 요구사항을 동시에 만족시켰다. 해당 연구에서는 SLA 위반 여부를 보상 함수에 직접 반영함으로 지연 민감 서비스에 대한 우선적 자원 보장을 유도하였다.

그러나 단일 에이전트 기반 방식은 슬라이스 수가 증가할수록 상태 및 행동 공간이 급격히 확장되는 문제를 가지기 때문에 대규모 RAN 환경에서의 확장성과 유연성을 제한한다.

II-2. 멀티 에이전트 기반 RL RAN 슬라이싱 기법

최근 연구들은 단일 에이전트 방식의 확장성 한계를 극복하기 위해 멀티 에이전트 강화학습 (Multi-Agent Reinforcement Learning, MARL) 기반 RAN 슬라이싱 구조를 도입하고 있다. MARL 기반 접근법에서는 각 슬라이스를 개별 에이전트로 모델링하여 자원 할당을 수행한다.

[8]은 슬라이스 수가 동적으로 변화하는 시나리오에서도 안정적인 SLA 보장을 달성하기 위해 제약 조건 기반 협력 MARL 기법을 제안하였다. 해당 연구는 각 슬라이스를 개별 에이전트로 모델링하면서 SLA 위반을 명시적인 제약 조건으로 포함시켰다. 이를 통해 보상 최대화 과정에서 발생할 수 있는 과도한 자원 소비 및 특정 슬라이스의 SLA 위반을 구조적으로 억제하였고, 슬라이스 간 경쟁이 존재하는 상황에서 전체 시스템의 안정성과 공정성을 동시에 확보할 수 있음을 보였다.

[9]은 RAN 슬라이싱 문제를 부분 관측 확률 게임 (POSG) 으로 모델링 하여 각 에이전트가 제한된 로컬 정보만을 관측하는 현실적인 RAN 환경을 반영하였다. 제안된 프레임워크는 각 슬라이스 에이전트가 독립적으로 정책을 학습하면서 전역 자원 제약을 고려한 협력적 의사결정 구조를 통해 전체 시스템의 SLA 만족을 유도한다. 또한 병렬적인 정책 실행 구조를 사용함으로 슬라이스 수가 늘어나는 환경에서도 계산 지연을 완화하고 실시간 RAN 제어에 적합한 학습 기반 자원 할당을 가능하게 한다.

이러한 MARL 기반 기법들은 슬라이스별 독립성과 전체 시스템 최적성 간의 균형을 달성함으로써, 대규모 RAN 슬라이싱 환경에서의 실질적인 적용 가능성을 크게 향상시킨다.

II-3. FL 기반 RAN 슬라이싱 기법

최근에는 중앙집중형 학습 구조의 한계를 극복하고, 보안 및 확장성을 동시에 고려하기 위한 FL 기반 RAN 슬라이싱 기법이 제안되고 있다. FL 기반 접근법에서는 각 RAN 엣지 노드 또는 슬라이스 관리 주체가 로컬 데이터를 기반으로 정책을 학습하고, 모델 파라미터만을 집계함으로써 데이터 공유 부담을 최소화한다.

[7]은 6G 제로터치 네트워크 슬라이싱 시나리오를 고려하여, SLA 제약을 명시적으로 포함한 확률적 FL 기반 자원 프로비저닝 정책을 제안했다. 해당 연구에서는 RAN-Edge에 분산된 분석 엔진들이 각 슬라이스에 대해 로컬 학습을 수행하고, SLA 위반률을 핵심 지표로 활용하여 FL 참여 노드를 확률적으로 선택하는 메커니즘을 설계하였다. 이를 통해 SLA 위반 가능성이 낮은 노드의 기여도를 높이면서도, 일부 SLA 위반 노드의 데이터 특성을 제한적으로 반영하여 모델의 일반화를 유지한다.

III. 결론

본 논문에서는 SLA 보장을 목표로 하는 지능형 RAN 슬라이싱 기법의 기술적 흐름을 분석하고 강화학습 및 연합학습 기반 접근법을 정리하였다. 단일 에이전트 기반 RL 기법은 동적 무선 환경에서 슬라이스별 자원 제어의 가능성을 제시하였으나, 슬라이스 수 증가에 따른 확장성 한계를 보였다. 이에 따라 멀티에이전트 강화학습 기반 기법들은 분산적 의사결정을 통해 대규모 RAN 환경에서도 SLA 인지형 자원 할당을 가능하게 하는 방향으로 발전하였다. 또한 FL 기반 접근법은 중앙집중형 학습의 한계를 극복하고, SLA 위반을 효과적으로 제어할 수 있는 확장 가능한 해결책을 제시하였다. 향후 RAN 슬라이싱 기술은 단순한 자원 분할을 넘어, SLA 인지형 학습 구조와 네이티브 AI 제어를 통합한 자율 및 지능적 네트워크 운영으로 진화할 것으로 예상된다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-대학ICT연구센터(ITRC)의 지원을 받아 수행된 연구임 (IITP-2026-RS-2022-00156353, 50% / IITP-2026-RS-2024-00436887, 50%)

참 고 문 헌

[1] K. Alam, M. A. Habibi, M. Tammen, D. Krummacker, W. Saad, M. D. Renzo, T. Melodia, X. C-. Perez, M. Debbah, A. Dutta, and H. D. Schotten, "A Comprehensive Tutorial and Survey of O-RAN: Exploring Slicing-Aware Architecture, Deployment Options, Use Cases, and Challenges," *IEEE Communications Surveys & Tutorials*, vol. 28, pp. 1637-1678, 2026.

[2] J. Dai, L. Li, R. Safavinejad, S. Mahboob, H. Chen, V. V. Ratnam,

H. Wang, J. Zhang, and L. Liu, "O-RAN-Enabled Intelligent Network Slicing to Meet Service-Level Agreement (SLA)," *IEEE Transactions on Mobile Computing*, vol. 24, no. 2, pp. 890-906, February 2025.

[3] K. Yu, H. Zhou, Z. Tang, X. Shen, and F. Hou, "Deep Reinforcement Learning-Based RAN Slicing for UL/DL Decoupled Cellular V2X," *IEEE Transactions on Wireless Communications*, vol. 21, no. 5, pp. 3523-3535, May 2022.

[4] T. K. Rodrigues, and N. Kato, "Network Slicing with Centralized and Distributed Reinforcement Learning for Combined Satellite/Ground Networks in a 6G Environment," *IEEE Wireless Communications*, vol. 29, no. 1, pp. 104-110, February 2022.

[5] J. Kim, G. Caire, and A. F. Molisch, "Quality-Aware Streaming and Scheduling for Device-to-Device Video Delivery," *IEEE/ACM Transactions on Networking*, vol. 24, no. 4, pp. 2319-2331, August 2016.

[6] W. J. Yun, D. Kwon, M. Choi, J. Kim, G. Caire, and A. F. Molisch, "Quality-Aware Deep Reinforcement Learning for Streaming in Infrastructure-Assisted Connected Vehicles," *IEEE Transactions on Vehicular Technology*, vol. 71, no. 2, pp. 2002-2017, February 2022.

[7] S. Roy, H. Chergui, L. S-. Russo, and C. Verikoukis, "A Cloud Native SLA-Driven Stochastic Federated Learning Policy for 6G Zero-Touch Network Slicing," in *Proc. of ICC 2022 - IEEE International Conference on Communications*, Seoul, Korea, pp. 4269-4274, 2022.

[8] M. Zangoeei, M. Golkarifard, M. Rouili, N. Saha, and R. Boutaba, "Flexible RAN Slicing in Open RAN With Constrained Multi-Agent Reinforcement Learning," *IEEE Journal on Selected Areas in Communications*, vol. 42, no. 2, pp. 280-294, February 2024.

[9] Y. Li, H. Wang, G. Min, X. Wang, and C. Wang, "A Flexible and Scalable Multi-Agent Learning Framework for Dynamic RAN Slicing in 6G Native-AI Networks," *IEEE Transactions on Mobile Computing*, Early Access, 2025.