

트래픽 예측 기반 심층강화학습을 활용한 최적 네트워크 슬라이싱 기법

윤재영, 이호원

아주대학교

dbswo0617@ajou.ac.kr, howon@ajou.ac.kr

Traffic Prediction-Based Deep Q-Network for Optimal Network Slicing

Jaeyoung Yun, Howon Lee

Ajou Univ.

요약

본 논문은 서로 다른 quality of service(QoS) 및 트래픽 요구를 갖는 다중 셀 환경을 대상으로, open RAN(O-RAN) 아키텍처의 RAN intelligent controller(RIC)에서 artificial intelligence(AI) 기술을 적용하여 트래픽 예측을 활용한 심층강화학습 기반 대역폭 슬라이싱 기법을 제안한다. 동적으로 변화하는 트래픽 상태에 대응하여 셀 간의 fairness를 고려하면서, 각 셀의 QoS 요구를 충족할 수 있도록 자원 할당을 최적화한다.

I. 서론

미래 네트워크는 고속 전송, 저지연, 고신뢰성 등 다양한 성능 요구 사항을 가진 서비스를 단일의 물리적 네트워크 인프라에 통합해야 하며, 각 서비스에 맞게 자원을 동적으로 공유하고 할당할 수 있어야 한다 [1, 2]. 네트워크가 점점 더 복잡해지는 환경에서, open RAN(O-RAN)은 개방형 아키텍처, RAN 가상화 및 지능화로 RAN 슬라이싱을 더욱 유연하게 한다. 특히 RAN intelligent controller(RIC)는 artificial intelligence(AI) 활용을 가능하게 하여 동적 자원 할당을 실현하고, 네트워크 전반의 효율성을 최적화할 수 있다 [3]. 따라서 서로 다른 quality of service(QoS) 및 트래픽 요구를 가진 셀들을 효과적으로 지원하기 위해 O-RAN 아키텍처에서 트래픽 예측을 활용한 심층강화학습 기반 대역폭 슬라이싱 기법을 제안한다.

II. 시스템 모델 및 대역폭 슬라이싱 기법

본 논문은 non-real-time(non-RT) RIC에서 트래픽을 예측하고, 예측된 트래픽 정보를 활용하여 near-real-time(near-RT) RIC에서 심층강화학습을 기반으로 자원 할당 정책을 결정한다. 해당 정책은 centralized unit(CU) 및 distributed unit(DU)로 전송되어 자원 할당이 수행된다 [4]. 각 셀은 시간에 따라 변화하는 트래픽 특성과 제공하는 서비스 유형에 따라 상이한 QoS 요구사항을 가지므로 고정적인 자원 할당 방식만으로는 이러한 요구를 효과적으로 충족시키기 어렵다. 이에 따라 동적인 환경에 적응적이고 유연한 자원 할당 기법이 필수적이다. 본 논문에서는 이를 위해 심층강화학습 기반 자원 할당 기법을 제안하며, Markov decision process(MDP)는 다음과 같이 정의된다.

- **State:** 각 셀 i 에 대해 실제 트래픽 요구량 $D_{real,i}^{t-1}$, 예측 트래픽 요구량 $D_{predict,i}^t$, QoS 요구를 충족하는 사용자 수 Q_i^{t-1} , 대역폭 분할 비율 α^{t-1} 로 구성된다.

$$S(t) = \{D_{real,i}^{t-1}, D_{predict,i}^t, Q_i^{t-1}, \alpha^{t-1}\}. \quad (1)$$

- **Action:** 현재 타임스텝의 대역폭 분할 비율을 결정한다.

$$A(t) = \alpha^t, \alpha^t \in \{0.1, 0.2, \dots, 0.9\}. \quad (2)$$

- **Reward:** 공정성과 QoS 보장에 대한 목표를 달성하기 위해 Jain's fairness index와 QoS를 충족하는 사용자 수를 포함하여 보상을 설계하였다.

$$R(t) = \frac{(\sum_{i=1}^n x_i^t)^2}{n \sum_{i=1}^n (x_i^t)^2} e^{\left(\sum_{i=1}^n \frac{Q_i^t}{\psi}\right)}, \quad (3)$$

위 수식에서, n 은 전체 셀 개수, $r_{i,u}^t$ 는 셀 i 에서 사용자 u 의 data rate, $x_i^t = \min(\sum_{u=1}^U r_{i,u}^t, D_{real,i}^t) / D_{real,i}^t$ 는 셀 i 에서 실제 트래픽 요구 대비 sum rate, ψ 는 sensitivity factor이다.

III. 시뮬레이션 결과 및 결론




그림 1. Average Reward vs. Episode.

본 논문은 QoS 및 트래픽 요구가 다른 두 셀에 대하여 자원 할당 기법을 비교한 결과이다. 제안한 방식은 무작위 행동 선택(Random Action) 방식에 비해 최적해에 더욱 근접하면서도 안정적으로 수렴함을 확인하였다. 이를 통해 제안 기법이 셀 간 공정성을 확보하는 동시에 QoS를 효과적으로 향상시키는 자원 할당을 수행할 수 있음을 입증한다.

ACKNOWLEDGMENT

이 논문은 2024년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원(No. RS-2024-00396992, 저궤도 위성통신 핵심 기술 기반 큐브 위성 개발)과 2022년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원(No. 2022-0-00704, 초고속 이동체 지원을 위한 3D-NET 핵심 기술 개발)과 2025년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원(RS-2025-00563401, 3차원 공간에서 에너지 효율적 멀티레벨 AI-RAN 구현을 위한 AI-for/and-RAN 핵심 원천 기술 연구)를 받아 수행된 연구임.

참고 문헌

- [1] H. Lee et al., "Towards 6G hyper-connectivity: Vision, challenges, and key enabling technologies," in Journal of Communications and Networks, vol. 25, no. 3, pp. 344-354, June 2023.
- [2] "O-RAN: Towards an open and smart RAN," O-RAN Alliance e.V., Alfter, Germany, White Paper, Oct. 2018.
- [3] X. Li et al., "Network Slicing for 5G: Challenges and Opportunities," in IEEE Internet Computing, vol. 21, no. 5, pp. 20-27, 2017.
- [4] F. Kavehmadavani, V. -D. Nguyen, T. X. Vu and S. Chatzinotas, "Intelligent Traffic Steering in Beyond 5G Open RAN Based on LSTM Traffic Prediction," in IEEE Transactions on Wireless Communications, vol. 22, no. 11, pp. 7727-7742, Nov. 2023.