

강화학습 기반 캐리어 로드 밸런싱 문제 설정과 성능 분석

심훈성, 이인규*

고려대학교 전기전자공학과

loski0922@korea.ac.kr, inkyu@korea.ac.kr

Problem Formulation and Performance Analysis of Reinforcement Learning based Carrier Load Balancing

Hoonseong Sim and Inkyu Lee*

School of Electrical Engineering, Korea University

요약

본 논문은 Carrier Load Balancing 문제를 강화학습(Reinforcement Learning, RL) 관점에서 정의하고 switching cost를 포함한 단순화된 환경을 구성하여 강화학습 접근법의 가능성을 제시한다. Q-learning 기반 에이전트는 즉각적인 부하 균형뿐만 아니라 장기적인 보상을 고려하여 적절한 캐리어 할당 정책을 학습한다. 본 연구는 향후 다중 캐리어 및 동적 사용자 환경으로의 확장을 위한 자료로 활용될 수 있다.

I. 서론

이동통신 시스템의 고도화와 함께 다중 캐리어 환경에서의 자원 관리 문제는 복잡해지고 있다. LTE-Advanced 및 5G NR 시스템에서는 Carrier Aggregation이나 Dual Connectivity 등 다수의 캐리어를 활용한 전송 구조가 일반화되었으며 이에 따라 사용자 트래픽을 적절히 분산시키는 Carrier Load Balancing의 중요성이 부각되고 있다.

기존의 Carrier Load Balancing 기법은 두 캐리어 간 부하 차이가 특정 임계값을 초과할 경우 사용자를 다른 캐리어로 이동시키는 규칙 기반 방식이 주를 이루었다. 이러한 접근법은 구현이 간단하다는 장점이 있으나 트래픽 변동이 심한 환경에서는 불필요한 사용자 이동을 반복적으로 발생시키는 문제가 있다. 특히 실제 이동통신 시스템에서 핸드오버는 제어 신호 증가와 지연, 패킷 손실 가능성 등 명확한 비용을 수반하므로 단순한 부하 균형만을 기준으로 한 의사결정은 시스템 성능을 저하시킬 수 있다.

최근 이러한 한계를 극복하기 위해 강화학습을 활용한 Load Balancing 연구가 활발히 진행되고 있다. [1]에서는 통신 네트워크 전반에서 강화학습 기반 Load Balancing 기법들을 정리하고 기존 규칙 기반 방식의 한계와 함께 향후 연구 방향을 제시하였다. 또한 [2]에서는 이동통신 환경에서 강화학습을 이용해 사용자 연결을 제어함으로써 Load Balancing과 핸드오버 비용을 동시에 고려하는 방법을 제안하였다.

본 논문에서는 Carrier Load Balancing을 강화학습 문제로 정의하고 switching cost가 존재하는 환경에서의 시뮬레이션을 통해 강화학습 기반 접근법의 가능성을 검증한다. 본 연구는 실제 시스템에 즉시 적용하기 위한 완성형 연구가 아닌, 보다 현실적인 모델로 확장하기 위한 기초 연구를 목표로 한다.

II. 본론

본 연구에서는 두 개의 캐리어를 가지는 단순화된 이동통신 시스템을 가정하며 각 사용자의 트래픽 요구량은 이전 시점의 상태에 의존하여 확률적으로 변동하는 시간 상관적 트래픽 과정으로 모델링한다. 시스템 내 캐리어는

60Mbps의 용량을 가지며 캐리어 간 부하 불균형이 커지거나 용량을 초과할 경우 시스템 전체의 성능 저하가 발생한다.

본 연구에서는 강화학습의 상태 s_t 를 두 개의 캐리어에 대한 트래픽 부하로 정의한다. 시간 t 에서 캐리어 k 의 총 부하 $L_k(t)$ 는 해당 캐리어에 할당된 사용자들의 트래픽 합으로 계산된다. 연속적인 상태 공간을 줄이기 위해 각 캐리어의 부하 $L_k(t)$ 를 고정된 bin 크기 Δ 로 이산화하여 다음과 같이 정의한다.

$$b_k(t) = \left\lfloor \frac{L_k(t)}{\Delta} \right\rfloor, k \in \{0, 1\} \quad (1)$$

이를 통해 강화학습의 상태를 $s_t = (b_0(t), b_1(t))$ 로 정의한다. 행동 $a_t \in \{0, 1, 2\}$ 는 각각 사용자 이동 없음, 캐리어 0에서 1로 이동, 캐리어 1에서 0으로 이동을 의미하며 이동 시 해당 캐리어 내 수요가 가장 큰 사용자 1명을 선택하여 이동시킨다. 사용자 이동 시에는 핸드오버에 따른 비용이 발생하도록 하고 이를 보상 함수에서 패널티 항으로 반영한다. 보상 함수는 각 캐리어에서 실제로 서비스된 처리량을 최대화되 사용자 이동에 따른 비용을 고려하도록 설계한다. 시간 t 에서의 보상 r_t 는 다음과 같이 정의된다.

$$r_t = \min(L_0(t), C_0) + \min(L_1(t), C_1) - c_{sw} \mathbf{1} \quad (2)$$

여기서 C_0, C_1 은 각 캐리어의 용량이며 c_{sw} 는 사용자 이동(핸드오버)에 따른 비용을 나타낸다. $\mathbf{1}$ 은 사용자 이동 여부를 나타내는 지시함수로 이동이 발생한 경우 1, 그렇지 않은 경우 0으로 정의된다. 이를 통해 강화학습 에이전트는 단기적인 부하 균형뿐만 아니라 장기적인 시스템 안정성까지 함께 고려하는 정책을 학습하도록 설계한다. 본 연구에서는 강화학습 기법 중 tabular Q-learning 기법을 적용하였다. 상태와 행동 공간이 이산적으로 정의되어 있으므로 각 상태-행동 쌍에 대한 Q-value를 테이블 형태로 저장하고 갱신하였다. 비교 기법으로는 캐리어 간 부하 차이가 특정 임계값을 초과할 경우 사용자를 이동시키는 규칙 기반 Load Balancing 기법을 사용하였다. 시뮬레이션은 총 1400 에피소드에 대해 수행되었고

각 에피소드는 80개의 스텝으로 구성된다. 학습 과정에서 강화학습 기반 방법은 초기에는 다소 불안정한 성능을 보이지만 에피소드가 진행됨에 따라 점진적으로 누적 보상이 증가하며 수렴하는 경향을 보인다.




그림 1. 에피소드에 따른 누적 보상 값

그림 1은 에피소드별 누적 보상의 이동 평균을 나타낸 결과이다. 강화학습 기반 방법은 학습이 진행됨에 따라 규칙 기반 방식보다 높은 평균 보상을 달성하며 특히 switching cost가 큰 환경에서 그 차이가 뚜렷하게 나타난다. 이는 강화학습 에이전트가 불필요한 캐리어 이동을 억제하고 이동이 정말 필요한 상황에서만 행동을 취하도록 학습했음을 의미한다.

III. 결론

본 논문에서는 Carrier Load Balancing 문제를 강화학습 관점에서 재정의하고 switching cost를 포함한 단순화된 문제의 시뮬레이션을 통해 강화학습 기반 접근법의 가능성을 제시하였다. 시뮬레이션 결과 강화학습 기반 방식은 단순한 규칙 기반 기법 대비 장기적인 보상을 고려한, 보다 안정적인 Load Balancing 정책을 학습할 수 있음을 확인하였다.

본 연구는 단순화된 환경을 기반으로 한 기초 연구 단계에 해당하며 실제 이동통신 시스템의 복잡성을 모두 반영하지는 않는다. 향후 연구에서는 다수 캐리어 확장과 사용자 이동성 모델 고도화와 실제 무선 채널 특성 및 지연 요소 반영 등을 통해 현실적인 강화학습 기반 Carrier Load Balancing 기법을 연구할 예정이다.

ACKNOWLEDGMENT

본 연구는 한국연구재단 및 정보통신기획평가원의 지원을 받아 수행된 연구임(RS-2022-NR070834)

참 고 문 헌

- [1] Wu, D., Li, J., Ferini, A., Xu, Y. T., Jenkin, M., Jang, S., Liu, X., & Dudek, G., "Reinforcement learning for communication load balancing: approaches and challenges," *Frontiers in Computer Science*, vol. 5, article 1156064, 2023.
- [2] Alizadeh, A., Lim, B., and Vu, M., "Multi-Agent Q-Learning for Real-Time Load Balancing User Association and Handover in Mobile Networks," *IEEE Transactions on Wireless Communications*, vol. 23, no. 8, pp. 9001 - 9015, Aug. 2024.