

재생 에너지 활용 스몰셀 네트워크의 심층 강화학습 기반 최적 자원 관리 기법

조혜빈, 김남이, 김형섭, 나지현, 임승찬^o, 이호원^{*}

한국전자통신연구원, 한경국립대학교^o, 아주대학교^{*}

{hbd1228, namikim, mobman, jhna}@etri.re.kr, sclim@hknu.ac.kr^o, howon@ajou.ac.kr^{*}

Deep Reinforcement Learning based Optimal Resource Management for Small Cell Networks by Renewable Energy

Hyebin Cho, Nam-I Kim, Hyungsub Kim, Jee-hyeon Na, Seung-Chan Lim^o, Howon Lee^{*}
Electronics and Telecommunications Research Institute, Hankyung National Univ^o, Ajou Univ^{*}

요약

본 연구에서는 재생 에너지 활용 이기종 스몰셀 네트워크의 한정적인 배터리 자원을 효율적으로 관리하여 네트워크의 간섭 문제를 해결하고 에너지 효율을 향상시키기 위한 심층 강화학습 기반 자원 관리 기법을 제안한다. Markov decision process (MDP)를 정의하고 시뮬레이션을 통해 제안 방안이 여러 비교 방안 대비 높은 에너지 효율 성능과 적은 아웃타지 유저 발생을 달성을 보인다.

I. 서 론

최근 기하급수적으로 증가하는 트래픽으로 인해 무선 통신 네트워크의 밀집화가 요구된다 [1]. 스몰셀 기술은 폭발적으로 증가하는 트래픽을 수용하고 에너지 소모량을 크게 감소시킬 수 있는 차세대 유망 기술 중 하나이다 [2-3]. 그러나, 밀집화로 인해 발생하는 심각한 간섭 문제와 여전히 존재하는 큰 에너지 소모량은 차세대 네트워크에서 반드시 해결되어야 한다 [4]. 따라서, 본 연구에서는 재생 에너지를 활용하는 이기종 스몰셀 네트워크에서의 심층 강화학습 기반 전력 제어 기법을 제안한다.

II. 시스템 모델 및 제안 방안

기준 유선 전력망을 통해 전력을 공급받는 macro base station (MBS) 집합 $\mathbb{M} = \{1, 2, \dots, M\}$ 과, 태양광 기반 에너지 하베스팅을 통해 충전된 전력으로 운영되는 small base station (SBS) 집합 $\mathbb{S} = \{1, 2, \dots, S\}$ 으로 구성된 이기종 스몰셀 네트워크 환경을 고려한다. 사용자 집합 $\mathbb{U} = \{1, 2, \dots, U\}$ 은 네트워크 영역에 임의로 분포되어 있으며, 각 사용자는 수신하는 signal-to-interference-plus-noise ratio (SINR)가 가장 높은 기지국에 접속을 시도한다. 각 기지국은 N_{ch} 개의 채널을 통해 사용자에게 서비스를 제공하며, 하나의 채널에는 오직 한 명의 사용자만 연결될 수 있다. 만약 기지국에 접속 요청한 사용자 수가 가용 채널 수를 초과하는 경우, 해당 기지국은 SINR 기준으로 높은 순서에서부터 채널을 할당한다. 이때, 기지국 $n \in \mathbb{M} \cup \mathbb{S}$ 와 사용자 u 간의 시간 t 에서의 SINR은 다음과 같이 정의된다:

$$\Gamma_{n,u,t} = \frac{P_{n,u,t}^{\text{RX}}}{\sum_{i \in \mathbb{M} \cup \mathbb{S}, i \neq n} P_{i,u,t}^{\text{RX}} + \sigma^2}, \quad (1)$$

여기서 $P_{n,u,t}^{\text{RX}}$ 는 기지국 n 로부터 사용자 u 가 수신하는 전력을 나타내며, σ^2 는 열 잡음 전력을 의미한다. 동일 채널에서 다른 기지국들로부터 수신되는 전력은 간섭으로 간주된다. 또한, 네트워크의 연결 품질 보장을 위해 사용자의 SINR이 미리 정의된 임계값 이상일 때만 해당 사용자에게 기지국 접속이 허용된다. 반대로, SINR이 기준에 미치지 못하거나 채널 부족으로 인해 연결되지 못한 사용자는 outage user ζ_t 로 간주한다.

제안 기법의 Markov decision process (MDP)는 다음과 같이 정의된다. 각 기지국은 독립적인 에이전트로 정의되며, $n \in \mathbb{M} \cup \mathbb{S}$ 로 표현된다. MBS의 상태 정보는 기지국의 전송 전력 $P_{n,t}^{\text{TX}}$, 날씨 정보 $C_{n,t}$, 연중일에 대한 시간 정보 T_t 를 포함하며, SBS의 상태 정보는 추가적으로 하베스팅되는 전력량 $P_{n,t}^{\text{EH}}$ 과 자신의 잔여 배터리 양 $B_{n,t}$ 이 포함된다. 각 에이전트는 자신의 상태 정보를 통해 행동을 선택하며, 선택 가능한 행동 집합은 $A_n = \{\pm \Delta P_n, 0\}$ 로 정의된다. 선택된 행동에 대한 보상은 네트워크의 에너지 효율을 향상시키고, outage user 발생을 줄일 수 있도록 정의되며, 식 (2)와 같이 나타낸다.

$$r_t = \frac{\sum_{n \in \mathbb{M} \cup \mathbb{S}} \sum_{u \in \mathbb{U}} \frac{W}{U} \log_2 (1 + \Gamma_{n,u,t})}{\sum_{m \in \mathbb{M}} P_{m,t}^{\text{C}}} \exp(-\rho \frac{\zeta_t}{U}). \quad (2)$$

여기서 W 는 각 기지국에 할당된 대역폭을 의미하며, $P_{m,t}^{\text{C}}$ 는 MBS의 총 소비 전력을 의미한다. 이때, 태양광 에너지를 통해 전력을 공급받는 스몰셀 기

지국의 소비전력은 네트워크 에너지 효율 계산에서 제외된다. ρ 는 아웃타지 유저의 폐널티 가중치를 조절하는 파라미터를 의미한다.

III. 시뮬레이션 결과 및 분석

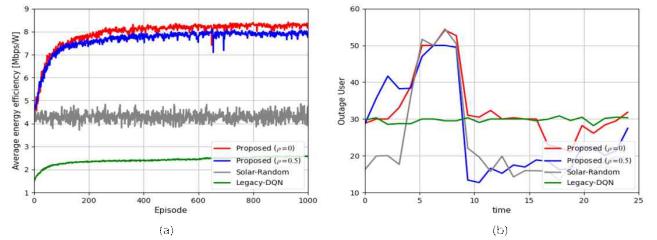


그림 1. (a) $M=1, S=5, U=60$ 환경에서의 에너지 효율 학습 그래프, (b) 하루동안 알고리즘 별 아웃타지 유저 발생 추이

그림 1-(a)는 $M=1, S=5, U=60$ 의 이기종 스몰셀 네트워크에서 각 알고리즘 별 에너지 효율 학습 그래프를 나타내며, 그림 1-(b)는 하루동안 각 알고리즘 별 아웃타지 유저 발생 추이를 나타낸다. 제안 기법은 에너지 효율 극대화 $\rho = 0$ 및 에너지 효율과 사용자 연결성의 균형 $\rho = 0.5$ 을 모두 고려한 설정에서 기준 전력 제어 기법들보다 우수한 성능을 보였다. 평균 에너지 효율은 7.88-8.19 Mbps/W로, Legacy-DQN 대비 약 3배 이상 향상되었으며, 이는 태양광 에너지 수확을 활용한 소형 셀 네트워크에서의 효과적인 간섭 제어 및 전력 제어 전략의 강점을 보여준다. 또한 $\rho = 0.5$ 설정은 사용자 단절 수를 평균 26.54명으로 낮춰 Legacy-DQN 대비 9.2% 개선된 연결성을 유지하였고, $\rho = 0$ 설정은 에너지 효율은 가장 높지만 사용자 단절이 더 많아지는 트레이드오프를 나타냈다. 이를 통해 제안 방안은 에너지 효율과 사용자 연결성 간의 균형을 효과적으로 달성을 입증하였다.

ACKNOWLEDGMENT

이 논문은 2025년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No. RS-2024-00396828, AI 기반 저전력 5G-A O-DU/O-CU 기술 개발)

참 고 문 헌

- [1] H. Lee, et al. "Towards 6G hyper-connectivity: Vision, challenges, and key enabling technologies," *Journal of Communications and Networks*, vol. 25, no. 3, pp. 344-354, Jun. 2023.
- [2] J. Moon, et al. "Trend of 5G NR Based Open Small Cell Technologies," *ETRI Electronics and Telecommunications Trends*, vol. 33, no. 5, pp. 33-41, Oct. 2018.
- [3] E. Kim, et al. "Optimal Resource Allocation Considering Non-Uniform Spatial Traffic Distribution in Ultra-Dense Networks: Multi-Agent Reinforcement Learning Approach," *IEEE Access*, vol. 10, pp. 20455-20464, Feb. 2022.
- [4] I. Hwang, et al. "A holistic view on hyper-dense heterogeneous and small cell networks," *IEEE Communications Magazine*, vol. 51, no. 6, pp. 20-27, Jun. 2013.