

UAV 지원 MEC 시스템의 로드 밸런싱과 에너지 효율성을 고려한 강화학습 기반 태스크 마이그레이션

신아영, 임유진
숙명여자대학교 IT공학과
ayoung7@sookmyung.ac.kr, yujin91@sookmyung.ac.kr

Task Migration for Load Balancing and Energy Efficiency based on Reinforcement Learning in UAV-Enabled MEC System

A Young Shin, Yujin Lim
Dept. of IT engineering, Sookmyung Women's University

요 약

최근 사물 인터넷(IoT)의 발전으로 계산 집약적이거나 지연시간에 민감한 태스크가 증가하면서, 모바일 엣지 컴퓨팅 기술이 주목받고 있지만 지상에 고정되어 있는 MEC 서버는 사용자의 요구사항 변화에 따라 서버의 위치를 변경하거나 유연하게 대처할 수 없다. 이 문제를 해결하기 위해 UAV(Unmanned Aerial Vehicle)를 추가로 이용해 엣지 서비스를 제공하는 기법이 연구되고 있다. 그러나 UAV는 지상 MEC와는 달리 배터리 용량이 제한되어 있어 태스크 마이그레이션을 통해 에너지 사용량을 최소화하는 것이 필요하다. 본 논문에서는 MEC 서버들 사이의 로드 밸런싱과 UAV MEC 서버의 에너지 효율성을 최적화하기 위해 강화학습 기법인 Q-learning을 이용한 태스크 마이그레이션 기법을 제안한다. 제안 시스템의 성능을 평가하기 위해 UAV의 개수에 따라 실험을 진행하여 잔여 에너지와 로드 밸런싱 측면에서 성능을 분석한다.

1. 서론

사물 인터넷(IoT)의 발전으로 무선 네트워크에서 생성되는 태스크의 수가 증가하고 있으며, 이러한 태스크 중 일부는 지연 시간에 민감하거나, 계산 집약적이다. 하지만, 모바일 디바이스는 컴퓨팅 능력과 배터리 용량에 한계가 있기 때문에 발생하는 태스크를 모두 로컬에서 스스로 처리하는 데는 어려움이 있다. 이를 해결하기 위해 네트워크 엣지에 서버를 배치하는 모바일 엣지 컴퓨팅(Mobile Edge Computing, MEC)이 등장하였다. 이는 기존의 클라우드 컴퓨팅에 비해 지리적으로 모바일 사용자와 가까워 더 빠르게 응답할 수 있다. 이러한 지상 MEC 서버는 일반적으로 고정되어 있어 모바일 사용자의 갑작스런 태스크 요구 상황에 따라 위치를 변경 또는 이동할 수 없기 때문에 MEC 서버의 기능이 제한된다. 예를 들어, 일시적으로 특정 공간에서 태스크 처리요청이 급증하는 상황이나 지형 상의 문제로 인해 유선 구조물을 설치할 수 없는 상황의 경우 지

상 MEC 서버의 활용은 제한적이다. 따라서 유연한 이동성과 쉬운 배치, 저렴한 비용 및 작은 크기의 장점을 가진 UAV(Unmanned Aerial Vehicle, UAV)를 추가로 이용해 모바일 엣지 서비스를 제공하는 연구가 진행되고 있다[1],[2].

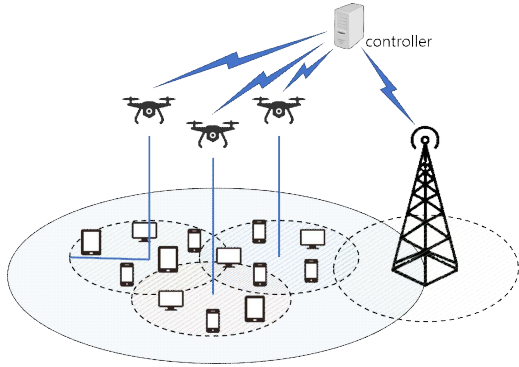
UAV는 MEC 서버가 되고, 리소스가 제한된 모바일 사용자는 태스크 부하가 높고 지연에 민감한 태스크를 MEC 서버에 오프로드 한다[3]. 하지만 지상 MEC 서버에 비해 UAV MEC 서버는 컴퓨팅 리소스의 한계가 있어 다수의 UAV와 지상 MEC 서버를 함께 이용하여 서비스를 제공할 수 있다. 이러한 환경에서 각 디바이스의 태스크 발생의 동적인 특성으로 인해 특정 서버에만 태스크가 집중되는 로드 불균형이 일어날 수 있으며, 이는 시스템 전체 처리량이 낮아지고 태스크 처리 지연시간이 늘어나는 문제를 초래한다. 뿐만 아니라, 배터리 용량이 제한되어 있는 UAV MEC 서버의 경우 너무 많은 태스크가 한 곳에 집중될 경우 오프로딩 된 모든 태스크를 수행하지 못하는 문제가 발생할 수 있다. 이러한 문

제는 MEC 서버들 간의 로드 밸런싱을 통해 지연시간을 최소화하고 처리량을 극대화할 수 있다.

따라서 본 논문에서는 각 디바이스의 태스크 발생과 태스크 크기가 동적인 환경에서 UAV서버들과 지상 MEC 모두 이용한 마이그레이션을 통한 로드 밸런싱을 하면서 UAV의 비행 에너지 및 연산에 필요한 에너지, 그리고 마이그레이션에 필요한 에너지를 모두 고려하여 총 에너지 사용량을 최소화하는 효율적인 태스크 마이그레이션 기법을 제안한다.

2. 시스템 모델

본 논문에서 제안하는 시스템은 (그림 1) 과 같이 $M-1$ 개의 UAV MEC 서버와 한 개의 지상 MEC 서버로 구성된다.



(그림 1) UAV MEC와 지상 MEC를 이용한 시스템.

이때 UAV MEC는 초기 설정된 위치에 고정되어 있다고 비행한다고 가정한다. UAV는 지상 MEC에 비해 지리적 제약 없이 초기 위치 설정이 가능하고, 지상 MEC는 정적 엣지 서버로서 UAV MEC 서버보다 더 강력한 컴퓨팅 능력을 가지고 있으며 지속적인 서비스를 제공할 수 있다[1]. 각 MEC 서버들은 컨트롤러와 연결되어 있으며, 서버들은 서로 무선 백홀(backhaul) 망을 통해 통신한다고 가정한다. 컨트롤러는 MEC 서버들의 상태 정보를 모두 수집하여 이를 바탕으로 각 MEC 서버에 오프로드된 태스크 중 해당 MEC에서 실행될 태스크와 마이그레이션 할 태스크를 결정한다. 마이그레이션은 UAV MEC 서버와 지상 MEC 모두 가능하며, 서비스 커버리지가 중복되는 이웃한 MEC 서버 중 중복 커버리지의 범위가 가장 넓은 서버 사이에서 일어난다고 가정한다. 타임 슬롯 t 에서 디바이스 n , $n \in N$ 에서 발생한 태스크 n 은 지리적으로 가장 가까운 MEC 서버에 오프로딩 되며, $\{f_n, i_n, T_n^{deadline}\}$ 으로 정의할 수 있고 f_n 는 태스크를 처리하는 데 필요한

CPU 사이클이고, i_n 는 태스크 사이즈, $T_n^{deadline}$ 은 태스크를 완료하기까지의 최대 지연시간이다. 각 태스크는 하나의 MEC 서버에서만 수행한다고 가정한다.

타임 슬롯 t 에서 UAV 혹은 지상 MEC m , $m \in M$ 의 로드 상태는 다음과 같다[1].

$$\beta_m^t = \frac{L_m^t}{L_m^{\max}} \quad (1)$$

L_m^t 는 타임 슬롯 t 에서 MEC m 의 태스크 큐 길이를 의미하며, L_m^{\max} 은 MEC m 의 가능한 최대 태스크 큐 길이이다.

타임 슬롯 t 에서 모든 MEC 서버들의 로드 평균은 다음과 같다.

$$LA^t = \frac{1}{M} \cdot \sum_{m=1}^M \beta_m^t \quad (2)$$

따라서 타임 슬롯 t 에서 모든 MEC 서버들의 로드 편차의 평균은 다음과 같다.

$$Load_{dev}^t = \frac{1}{M} \cdot \sum_{m=1}^M |\beta_m^t - LA^t| \quad (3)$$

UAV의 에너지 사용량은 비행 에너지 및 연산에 필요한 에너지, 그리고 마이그레이션에 필요한 에너지를 모두 고려해주어야 한다.

먼저, 본 논문에서는 UAV가 초기 설정된 위치에 고정되어 있다고 가정하였으므로, 타임 슬롯 t 에서 UAV m 의 비행 에너지는 설정된 위치에 떠있는 에너지만 고려하여 다음과 같이 계산한다.

$$E_{fly}^{t,m} = \frac{\delta \cdot \tau}{2} \cdot \|H_m^t\|^2 \quad (4)$$

δ 는 중력 가속도, H_m^t 는 UAV m 의 비행높이를 의미하며, τ 는 타임 슬롯 t 의 길이를 의미한다.

UAV m 가 ψ_1^m ($\psi_1^m \leq N$)개의 태스크 연산에 필요한 에너지는 다음과 같다. ψ_1^m 은 타임 슬롯 t 에서 발생한 태스크 N 개 중에서 UAV m 에 의해 실행될 태스크의 개수이다.

$$E_{comp}^{t,m} = k \cdot \sum_{n=1}^{\psi_1^m} f_{n,m} \cdot \tau \quad (5)$$

이때 k 는 UAV CPU의 유효 스위칭 전기용량 값이고, $f_{n,m}$ 은 태스크 n 의 실행을 위해 UAV m 에 요구되는 컴퓨팅 리소스를 의미한다[1].

UAV MEC m 이 다른 MEC 서버 m' 로 태스크 n 을 마이그레이션 할 때 필요한 에너지는 다음과 같다. ψ_2^m 은 타임 슬롯 t 에서 발생한 태스크 N 개 중에서 UAV m 에서 m' 로 마이그레이션되는 태스크의 개수이다.

$$E_{mig}^{t,m,m'} = \sum_{n=1}^{\psi_2^m} p_{m,m'}^{t,n} \cdot \frac{d_{m,m'} \cdot i_n}{V_b} \quad (6)$$

$p_{m,m'}^{t,n}$ 는 태스크 n 을 이웃한 MEC m' 로 마이그레이션 할 때 필요한 전송 전력이고, $\frac{d_{m,m'} \cdot i_n}{V_b}$ 은 무선 백홀 망을 통해 전송하는 데 걸리는 시간으로, $d_{m,m'}$ 은 MEC 서버 간 거리, V_b 는 백홀 채널의 전송 속도를 의미한다.

따라서 타임슬롯 t 에서 UAV m 의 총 에너지 사용량은 다음과 같다.

$$E_{total}^{t,m} = \phi_1 \cdot E_{fly}^{t,m} + \phi_2 \cdot E_{comp}^{t,m} + \phi_3 \cdot E_{mig}^{t,m,m'} \quad (7)$$

ϕ_1, ϕ_2, ϕ_3 ($0 \leq \phi_1, \phi_2, \phi_3 \leq 1, \phi_1 + \phi_2 + \phi_3 = 1$)은 가중치 요소로 세 가지 에너지 소비의 비율을 조정한다.

따라서 $M-1$ 개의 UAV MEC의 총 에너지 사용량은 다음과 같다.

$$E_{total}^t = \sum_{m=1}^{M-1} E_{total}^{t,m} \quad (8)$$

본 논문의 목표는 MEC 서버들의 로드밸런싱을 하면서 UAV의 총 에너지 사용량을 최소화하는 것이다. 따라서 다음과 같이 표현할 수 있다.

$$\begin{aligned} \min \quad & w \cdot Load_{dev}^t + (1-w) \cdot E_{total}^t \\ \text{s.t.} \quad & T_n \leq T_n^{deadline} \end{aligned} \quad (9)$$

T_n 은 태스크 n 완료까지의 지연시간이며, 이는 최대 허용가능한 지연시간보다 짧아야 한다.

이처럼 태스크 발생과 크기가 동적인 환경에서 해당 목표를 달성하기 위해서는 동적 변화에 따라 유연하게 마이그레이션 전략을 채택해야 한다. 강화학습은 환경을 인식하고 환경과의 상호 작용을 통해 의사 결정을 내릴 수 있기 때문에 해당 환경에 적합하다[4, 5]. 따라서 본 논문에서는 강화학습 방법 중 하나인 Q-learning을 이용한 마이그레이션 기법을 제안한다.

3. 제안하는 알고리즘


본 논문에서는 Q-learning을 기반으로 MEC 서버들 간의 로드 밸런싱과 UAV MEC 서버의 에너지를 고려한 마이그레이션 알고리즘을 제안한다.

본 논문에서의 Q-learning 알고리즘을 위한 상태 (s), 행동 (a), 보상 (r)에 대한 정의는 다음과 같다. UAV MEC 서버의 에너지 사용량을 최소화하기 위해 에너지 정보를 상태 정보에 반영해 주었다. MEC m 의 타임 슬롯 t 에서의 상태 $S_m^t = \{l_m^t, \alpha_m^t, \beta_m^t, c_m^t\}$ 로 정의하고, l_m^t 는 MEC의 위치, α_m^t 는 MEC의 잔여 에너지 상태를 의미하며, β_m^t 는 MEC의 로드 상태, c_m^t 는 MEC에 오프로드된 태스크 수를 의미한다. 단, 지상 MEC의 경우 α_m^t 는 NULL 값으로 처리한다. 시스템에 $M-1$ 개의 UAV와 한 개의 지상 MEC가 존재하므로, MEC의 상태 공간 집합을 나타내기 위해 $S = \{S_1^t, S_2^t, \dots, S_M^t\}$ 로 정의한다. 이러한 상태를 기반으로 행동을 결정하며 행동 $A = \{a_{\psi_1}^1, a_{\psi_1}^2, a_{\psi_1}^3, \dots, a_{\psi_1}^m\}$ 으로 정의한다. 이는 각 MEC 별로 ψ_1^m 값을 결정하는 것으로, MEC m 에서 수행할 태스크 수와 종류를 결정한다. ψ_2^m 값은 MEC m 의 총 태스크 수에서 Q-learning 알고리즘에 의해 결정된 ψ_1^m 값을 뺀 값으로 한다. 컨트롤러는 행동에 의해 보상 r 을 얻는다. 본 논문에서는 식 (9) 과 같이 MEC 서버 간 로드 편차 평균과 UAV의 총 에너지 소비량을 최소화하기 위한 학습을 진행한다. 따라서 보상은 $r = -\{w \cdot Load_{dev}^t + (1-w) \cdot E_{total}^t\}$ 과 같다.

4. 실험 및 성능평가

제안하는 알고리즘의 성능을 평가하기 위해 200m × 200m 환경에서 1개의 고정 MEC와 UAV MEC가 2개, 3개, 4개 배치된 상황에 대해 각각 실험을 진행하였다. 각 MEC의 커버리지 반경은 100m이고, 태스크는 푸아송 분포로 발생한다고 가정하였다. 태스크 크기는 1.5 ~ 2 Mbits 사이에서 무작위로 선택하였다.


먼저 UAV 개수가 늘어남에 따른 총 잔여 에너지 비율을 비교해 보았다. 실험 결과는 (그림 2)와 같다.



(그림 2) UAV 개수에 따른 UAV 총 잔여 에너지 비율

UAV의 개수가 많아지면 에너지 소모 비율이 더 높아지게 되는데 이는 같은 크기 공간에서 UAV가 많아지면 겹치는 커버리지의 범위가 더 넓어지게 되고, MEC 간 태스크 마이그레이션이 더 많이 일어나게 되어 에너지 소모가 더 늘어나게 된다.

다음으로, UAV 개수에 따른 MEC들의 로드 밸런싱 정도를 살펴보기 위한 실험을 진행하였고, 실험 결과는 (그림 3)과 같다.



(그림 3) UAV 개수에 따른 MEC 로드 상태

UAV가 많아질수록 지상 MEC의 로드가 낮아지고 각 MEC 사이의 로드 편차가 작아지는 것으로 보아 로드밸런싱이 잘 이루어지고 있음을 확인할 수 있다.

5. 결론

본 논문에서는 UAV 지원 MEC 환경에서 Q-learning을 이용한 태스크 마이그레이션 기법을 제안하였다. 실험을 통하여 에너지를 고려한 마이그레이션을 통해 로드 밸런싱이 잘 이루어지고 있음을 확인할 수 있었다. 하지만 본 논문은 UAV의 이동성을 고려하지 않았으며 싱글 에이전트 환경이다. UAV의 이동성이 존재하는 더 동적인 환경에서 멀티 에이전트를 고려한 연구가 필요하다.

사사문구

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2021R1F1A1047113).

참고문헌

- [1] W. Ouyang, Z. Chen, J. Wu, G. Yu and H. Zhang "Dynamic Task Migration Combining Energy Efficiency and Load Balancing Optimization in Three-Tier UAV-Enabled Mobile Edge Computing System," MDPI Electronics, vol.10, no. 2, 190, 2021
- [2] H. Peng and X. -S. Shen, "DDPG-based Resource Management for MEC/UAV-Assisted Vehicular Networks," 2020 IEEE 92nd Vehicular Technology Conference (VTC2020-Fall), pp. 1-6, 2020.
- [3] C. Liu, F. Tang, Y. Hu, K. Li, Z. Tang and K. Li, "Distributed Task Migration Optimization in MEC by Extending Multi-Agent Deep Reinforcement Learning Approach," IEEE Transactions on Parallel and Distributed Systems, vol. 32, no. 7, pp. 1603-1614, July 2021.
- [4] X. He, M. Meng, S. Ding and H. Li, "A Survey of Task Migration Strategies in Mobile Edge Computing," 2021 IEEE 6th International Conference on Cloud Computing and Big Data Analytics (ICCCBDA), pp. 400-405, 2021.
- [5] D. Pandey and P. Pandey, "Approximate Q-Learning: An Introduction," 2010 Second International Conference on Machine Learning and Computing, pp. 317-320, 2010.