

UAV-MEC지원 차량 네트워크에서 트래픽 예측을 통한 DQN기반 태스크 마이그레이션

신아영, 임유진
숙명여자대학교 IT공학과
ayouong7@sookmyung.ac.kr, yujin91@sookmyung.ac.kr

DQN-Based Task Migration with Traffic Prediction in UAV-MEC assisted Vehicular Network

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

요 약


차량 환경에서 발생하는 계산 집약적인 태스크가 증가하면서 모바일 엣지 컴퓨팅(MEC, Mobile Edge Computing)의 필요성이 높아지고 있다. 하지만 지상에 존재하는 MEC 서버는 출퇴근 시간과 같이 태스크가 일시적으로 급증하는 상황에 유연적으로 대처할 수 없으며, 이러한 상황을 대비하기 위해 지상 MEC 서버를 추가로 설치하는 것은 자원의 낭비를 불러온다. 최근 이 문제를 해결하기 위해 UAV(Unmanned Aerial Vehicle)기반 MEC 서버를 추가로 사용해 엣지 서비스를 제공하는 연구가 진행되고 있다. 그러나 UAV MEC 서버는 지상 MEC 서버와 달리 한정적인 배터리 용량으로 인해 서버 간 로드밸런싱을 통해 에너지 사용량을 최소화 하는 것이 필요하다. 본 논문에서는 UAV MEC 서버의 에너지 사용량을 고려한 마이그레이션 기법을 제안한다. 또한 GRU(Gated Recurrent Unit) 모델을 활용한 트래픽 예측을 바탕으로 한 마이그레이션을 통해 지연시간을 최소화할 수 있도록 한다. 제안 시스템의 성능을 평가하기 위해 MEC의 마이그레이션 시점을 결정하는 기준점과 차량의 밀도에 따라 실험을 진행하고, 서버의 로드 편차, UAV MEC 서버의 에너지 사용량 그리고 평균 지연 시간 측면에서 성능을 분석한다.

1. 서론

최근 차량 환경에서 발생하는 지연시간에 민감하고 계산 집약적인 태스크를 빠르게 처리하기 위해 지리적으로 사용자와 가까운 모바일 엣지 컴퓨팅(MEC)에 대한 연구가 진행되고 있다. 하지만 기존 MEC 시스템의 경우 처리용량이 제한되어 있어 출퇴근 시간과 같이 트래픽이 일시적으로 증가하는 상황에 대해 유연하게 대처할 수 없다는 문제가 있다. 따라서 최근 UAV를 이용한 엣지 서비스가 연구되고 있다[1]. 하지만 UAV의 제한된 배터리 용량으로 인해 에너지 사용량을 고려한 MEC 서버(MECS)간 로드 밸런싱이 필요하며, 동적인 차량 환경에서 트래픽 발생량을 미리 예측하여 마이그레이션 한다면 더욱 효과적인 엣지 서비스 제공이 가능하다. 따라서 본 논문에서는 GRU를 활용하여 트래픽을 예측하고 이 정보를 바탕으로 UAV의 에너지 사용 총합 및 에너지 사용량 편차, 그리고 MECS간 로드 편차를 고려한 마이그레이션 기법을 제안한다.

2. 시스템 모델

본 논문에서 제안하는 시스템은 일시적으로 태스크가 급증하는 도심 지역 출퇴근 시간 환경을 가정하였고, (그림 1)과 같이 기존의 지상 MECS가 존재하는 환경에서 M 개의 UAV MECS가 추가된 환경을 가정하였다.



(그림 1) 시스템 모델

UAV MECS는 초기 설정 위치에 고정되어 있고 지상으로부터 100m 높이에서 비행하며, 태스크는 가장 가까운 MECS에 오프로딩 한다고 가정한다. MECS들은 모두 무선 백홀(backhaul)을 통해 통신하고, 하나의 컨트롤러와 연결되어 있다고 가정한다.

타임 슬롯 t 에서 모든 MECS의 로드 편차는 다음과 같다.

$$Load_{dev}^t = \sqrt{\frac{1}{M} \cdot \sum_{m=1}^M (|\beta_m^t - LA^t|)^2} \quad (1)$$

β_m^t 는 타임 슬롯 t 에서 MECS $m, m \in M$ 의 로드 상태를 의미하고, LA^t 는 타임 슬롯 t 에서 모든 MECS들의 로드 평균을 의미한다.

UAV의 에너지 사용량은 UAV가 공중에서 비행하는 에너지, 태스크 연산 에너지, 마이그레이션 시 필요한 에너지를 모두 고려해주어야 한다. 따라서 타임 슬롯 t 에서 UAV m 의 총 에너지 사용량은 식 (2)와 같다. $E_{fly}^{t,m}$ 은 비행 에너지, $E_{comp}^{t,m}$ 은 연산에 필요한 에너지를 의미하며, $E_{mig}^{t,m,m'}$ 은 다른 MECS m' 로 태스크를 마이그레이션 할 때 필요한 에너지를 의미한다.

$$E_{total}^{t,m} = E_{fly}^{t,m} + E_{comp}^{t,m} + E_{mig}^{t,m,m'} \quad (2)$$

따라서 에너지 편차는 식 (3)과 같다. E_{avr}^t 는 타임 슬롯 t 에서 MECS들의 에너지 사용량 평균을 의미한다.

$$E_{dev}^t = \frac{1}{M} \cdot \sum_{m=1}^M (|E_{total}^{t,m} - E_{avr}^t|)^2 \quad (3)$$

본 논문에서 제안하는 기법은 UAV MECS들의 총 에너지 사용량을 줄이면서 MECS간 로드 밸런싱을 하고자 한다. 다시 말해서, 모든 MECS가 에너지를 균등하게 사용하여 특정 MECS의 에너지만 모두 소진되지 않도록 MECS간 로드편차를 줄이고자 한다. 따라서 제안 기법의 목적은 식 (4)와 같이 표현할 수 있다. E_{total}^t 는 타임슬롯 t 에서 M 개 UAV의 총 에너지 소모량을 의미하고, w_1, w_2, w_3 은 0과 1사이 값들이며 합이 1인 가중치 값이다.

$$P: \min (w_1 \cdot E_{total}^t + w_2 \cdot E_{dev}^t + w_3 \cdot Load_{dev}^t) \quad (4)$$

3. 제안하는 알고리즘

본 논문에서는 GRU(Gated Recurrent Unit)를 기반으로 태스크 발생 트래픽을 예측하고, 이를 바탕으로 DQN(Deep Q-Network) 기반 마이그레이션 기법을 제안한다. GRU는 LSTM(Long Short-Term Memory) 구조를 더 간단하게 개선한 모델로 LSTM의 장기 의존성 문제를 해결하는 예측 모델이다[2]. 이 모델을 활용하여 각 UAV MECS내에서 발생할 태스크 수를 예측한다. 예측한 결과를 활용하여 DQN 기반의 마이그레이션을 수행한다. 본 논

문에서 정의한 DQN을 위한 상태(s), 행동(a), 보상(r)의 정의는 다음과 같다. UAV의 에너지와 다음 타임슬롯의 발생 트래픽을 고려하여 효과적인 마이그레이션을 하기 위해 각각의 MECS에 대해 $S_m^t = \{l_m^t, \beta_m^t, c_m^t\}$ 로 정의하고, l_m^t 는 타임슬롯 t 에서 MECS m 의 로드 상태, β_m^t 는 MECS m 의 에너지 상태, c_m^t 는 GRU를 활용하여 예측된 다음 타임슬롯에서 발생될 태스크양을 의미한다.

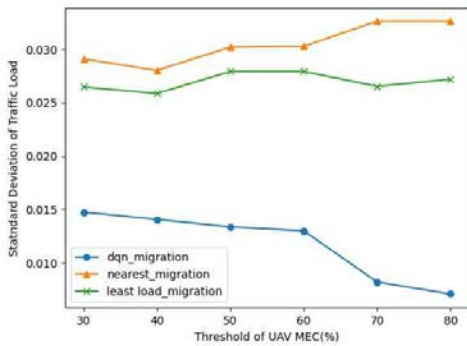
상태 공간 집합은 $S = \{S_1^t, S_2^t, \dots, S_M^t\}$ 로 정의한다. 행동 집합은

$A = \{a_1^1, \dots, a_1^m, \dots, a_2^1, \dots, a_2^m, \dots, a_m^1, a_m^2, \dots, a_m^m\}$ 로 정의한다. $a_{m_1}^{m_2}(m_1, m_2 \leq m)$ 은 MECS m_1 에서 MECS m_2 으로 마이그레이션 되는 태스크 수를 의미하며, m_1 과 m_2 가 같은 경우에는 마이그레이션하지 않는다. 에이전트는 행동에 따른 보상을 계산하며, 식 (4)와 같이 에너지 사용 총합, 에너지 편차 그리고 로드 편차를 최소화하는 방향으로 학습을 진행한다. 따라서 보상(r)은 부정적인 보상으로 $r = -(\phi_1 \cdot E_{total}^{nor} + \phi_2 \cdot E_{dev}^{nor} + \phi_3 \cdot Load_{dev}^{nor})$ 으로 정의한다. E_{total}^{nor} 은 에너지 총 사용량을 정규화한 값이고, E_{dev}^{nor} 은 에너지 사용 편차를 정규화한 값, 그리고 $Load_{dev}^{nor}$ 은 MECS의 로드 편차를 정규화한 값을 의미하며, ϕ_1, ϕ_2, ϕ_3 은 합이 1인 0과 1사이의 가중치 값이다.

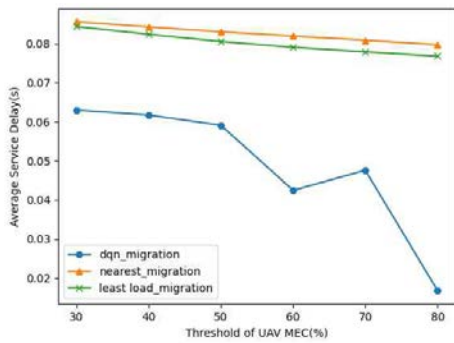
4. 실험 및 성능 평가

본 논문에서 제안하는 알고리즘의 성능을 평가하기 위해 $600m \times 600m$ 환경에서 1개의 지상 MECS와 4개의 UAV MECS가 배치된 환경에서 실험을 진행하였다. UAV MECS 한 개의 서비스 반경은 $200m$ 이며, 1개의 지상 MECS는 UAV MECS들의 서비스 반경을 모두 서비스할 수 있다고 가정한다. 태스크 사이즈는 $[100,150]MB$ 범위 내에서 무작위로 발생시켰으며, 차량의 위치 또한 푸아송 분포로 발생시켰다. 타임 슬롯의 길이는 $5s$ 로 설정하였고, 배터리 초기 용량은 $50kJ$ 이라고 가정한다. 본 논문에서 제안한 DQN기반 마이그레이션 기법의 성능을 평가하기 위해 가장 가까운 곳에 마이그레이션 하는 기법(nearest_migration), 로드 상태가 가장 낮은 MECS에 마이그레이션하는 기법(least_load_migration)과의 성능을 비교하였다. 먼저 MECS의 마이그레이션 시점을 결정하는 기준점을 달리하여 실험을 진행하였고 다음 타임슬롯에서 발생하는 트래픽이 기준점을 넘어갈 것으로 예상된다면 마이그레이션을 수행한다. 결과는 (그림 2), (그

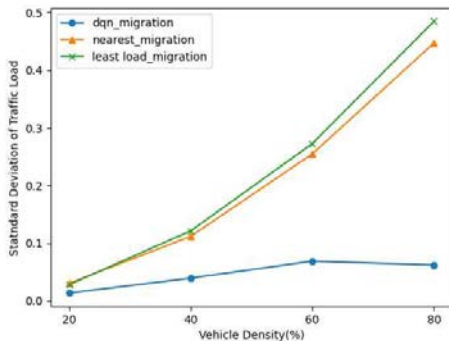
림 3)와 같다. 실험 결과 제안하는 기법이 다른 기법들 보다 로드 편차와 평균 서비스 지연시간이 작은 것으로 보아 로드 밸런싱이 잘 되었음을 알 수 있다. 다음으로 실험 범위 내의 차량 밀도를 변경하며 실험을 진행하였고, 결과는 (그림 4)과 같다. 가장 가까운 곳에 마이그레이션 하는 기법과 로드 상태가 가장 낮은 MECS에 마이그레이션하는 기법은 차량의 밀도가 늘어나면 로드 편차가 높아지지만, 제안하는 기법의 경우 차량의 밀도가 높아져도 로드 편차에 큰 차이가 없으며 항상 로드밸런싱이 잘 이루어진다는 것을 확인할 수 있다. 마지막으로 (그림 5)는 세가지 기법의 마이그레이션에 소모된 에너지이다. 제안하는 기법이 마이그레이션에 가장 작은 에너지를 소모한 것으로 보아 에너지 소모량을 최소화하며 마이그레이션을 수행하였음을 알 수 있다.



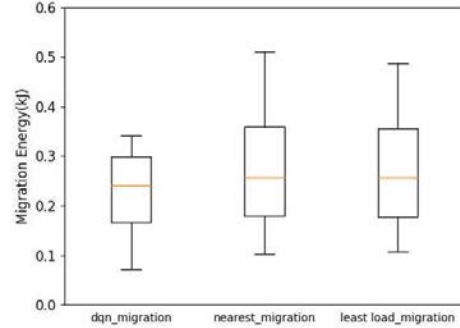
(그림 2) 마이그레이션 기준점에 따른 UAV MECS간 로드 편차



(그림 3) 마이그레이션 기준점에 따른 평균 서비스 지연시간



(그림 4) 차량의 밀도에 따른 UAV MECS간 로드 편차



(그림 5) 기법에 따른 마이그레이션에 소모된 에너지

5. 결론

본 논문에서는 태스크가 순간적으로 급증하는 시간동안 UAV MECS가 일시적으로 사용되는 차량 환경에서 UAV MECS의 에너지 상태를 고려하며 동적인 태스크 요청에 효과적으로 대응하기 위한 기법을 제안하였다. GRU를 기반으로 트래픽을 예측하고 그 정보를 바탕으로 한 DQN 기반의 마이그레이션 기법을 제안하였다. 제안하는 알고리즘의 성능을 평가하기 위해 가장 가까운 곳에 마이그레이션 하는 기법, 로드 상태가 가장 낮은 MECS에 오프로딩하는 기법, 그리고 제안하는 알고리즘의 성능을 분석하였고, 제안하는 기법을 사용했을 때 다른 두 기법 보다 에너지 사용량을 줄이면서 로드 밸런싱이 잘 이루어짐을 확인할 수 있었다. 향후 연구에서는 동적인 환경에서의 효율적인 학습을 위해 멀티 에이전트를 고려한 연구를 진행하고자 한다.

사사문구

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 ICT혁신인재4.0 사업과 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (IITP-2022(2022)-RS-2022-00156299) (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, pp. 1-30, 2021.
 [2] S. Wang, J. Zhao, C. Shao, C. Dong and C. Yin, “Truck Traffic Flow Prediction Based on LSTM and GRU Methods With Sampled GPS Data,” IEEE Access, vol. 8, pp. 208158-208169, 2020