

UAV-MEC Offloading and Migration Decision Algorithm for Load Balancing in Vehicular Edge Computing Network

A Young Shin[†] · Yujin Lim^{††}

ABSTRACT

Recently, research on mobile edge services has been conducted to handle computationally intensive and latency-sensitive tasks occurring in wireless networks. However, MEC, which is fixed on the ground, cannot flexibly cope with situations where task processing requests increase sharply, such as commuting time. To solve this problem, a technology that provides edge services using UAVs (Unmanned Aerial Vehicles) has emerged. Unlike ground MEC servers, UAVs have limited battery capacity, so it is necessary to optimize energy efficiency through load balancing between UAV MEC servers. Therefore, in this paper, we propose a load balancing technique with consideration of the energy state of UAVs and the mobility of vehicles. The proposed technique is composed of task offloading scheme using genetic algorithm and task migration scheme using Q-learning. To evaluate the performance of the proposed technique, experiments were conducted with varying mobility speed and number of vehicles, and performance was analyzed in terms of load variance, energy consumption, communication overhead, and delay constraint satisfaction rate.

Keywords : Mobile Edge Computing, Offloading, Migration, Genetic algorithm, Q-learning

차량 엣지 컴퓨팅 네트워크에서 로드 밸런싱을 위한 UAV-MEC 오프로딩 및 마이그레이션 결정 알고리즘

신 아 영[†] · 임 유 진^{††}

요 약

최근 무선 네트워크에서 발생하는 계산 집약적이고 지연시간에 민감한 태스크를 처리하기 위해 모바일 엣지 서비스에 대한 연구가 진행되고 있다. 하지만 지상에 고정되어 있는 MEC는 출퇴근 시간과 같이 태스크 처리 요청이 일시적으로 급증하는 상황에 대해 유연하게 대처할 수 없다. 이를 해결하기 위해 UAV(Unmanned Aerial Vehicle)를 추가로 이용해 모바일 엣지 서비스를 제공하는 기술이 등장하였다. UAV는 지상 MEC 서버와 달리 배터리 용량이 제한되어 있어 UAV MEC 서버 간 로드 밸런싱을 통해 에너지 효율성을 최적화 하는 것이 필요하다. 따라서 본 논문에서는 UAV의 에너지 상태와 차량의 이동성을 고려하며 유전 알고리즘 기반의 태스크 오프로딩과 Q-learning 기반의 태스크 마이그레이션을 통한 로드 밸런싱 기법을 제안한다. 제안 시스템의 성능을 평가하기 위해 차량 속도와 수에 따른 실험을 진행하고, 로드 분산, 에너지 사용량, 통신 오버헤드, 지연 시간 만족도 측면에서 성능을 분석하였다.

키워드 : 모바일 엣지 컴퓨팅, 오프로딩, 마이그레이션, 유전 알고리즘, 큐러닝

1. 서 론

최근 사물 인터넷의 발전으로 무선 네트워크에서 발생하

는 태스크가 증가하고 있는 한편, 모바일 디바이스는 배터리 용량과 컴퓨팅 능력의 한계로 지연시간에 민감하거나 계산 집약적인 태스크를 모두 로컬에서 스스로 처리하는데 한계가 있다. 이러한 문제를 해결하기 위해 기존의 클라우드 컴퓨팅에 비해 모바일 사용자와 지리적으로 가까운 모바일 엣지 컴퓨팅(Mobile Edge Computing, MEC)이 등장하였다. 그러나 지상에 고정된 MEC 서버는 처리 용량이 제한되어 있어 출퇴근 시간과 같이 교통 상황이 일시적으로 혼잡한 시간대에 갑작스럽게 증가하는 태스크 처리 요청에 유동적으로 대응할 수 없다. 그러나 이러한 상황을 해결하기 위해 추가적인 지상 MEC를 설치하는 것은 자원 활용 측면에

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

※ 이 논문은 2022년 한국정보처리학회 ASK 2022에서 "UAV 지원 MEC 시스템의 로드 밸런싱과 에너지 효율성을 고려한 강화학습 기반 태스크 마이그레이션"의 제목으로 발표된 논문을 확장한 것임.

† 준 회원 : 숙명여자대학교 IT공학과 석사과정

†† 종신회원 : 숙명여자대학교 IT공학과 교수

Manuscript Received : August 1, 2022

First Revision : September 20, 2022

Accepted : September 26, 2022

* Corresponding Author : Yujin Lim(yujin91@sookmyung.ac.kr)

서 좋지 않다. 따라서 이동성이 있는 UAV(Unmanned Aerial Vehicle, UAV)를 추가로 이용하여 일시적으로 증가하는 태스크 요청을 처리하는 모바일 엣지 서비스가 최근 들어 많이 고려되고 있다[1,2]. 하지만 차량 환경에서 사용자들의 높은 이동성으로 인해 MEC간 로드 불균형이 일어나거나 차량이 MEC 서버의 서비스 영역을 벗어나기 전에 태스크를 완료하지 못하는 문제가 발생할 수 있다. 또한, 지상 MEC에 비해 배터리 용량에 한계가 있는 UAV MEC 서버는 한 곳에 너무 많은 태스크가 집중될 경우 오프로딩된 태스크를 모두 완료하기 전에 배터리가 소진되어 오프로딩된 모든 태스크를 제한 시간 내에 수행하지 못하는 문제가 발생할 수 있다. 이러한 문제를 해결하기 위하여 UAV MEC의 로드 정도와 배터리 상태를 고려하여 태스크를 여러 개의 MEC 서버에 나누어 오프로딩하고, 차량의 이동 경로에 따른 태스크 마이그레이션을 통해 처리량을 늘리고 로드 불균형 문제를 해결할 수 있다.

따라서 본 논문에서는 UAV의 로드 상태와 에너지 상태를 고려한 유전 알고리즘 기반의 오프로딩 기법과 차량의 이동성 및 로드 분산, 통신 오버헤드를 고려한 강화학습 기반의 마이그레이션 기법을 제안한다. 또한 제안 시스템 환경에서 차량의 속도와 개수 변화에 따른 로드 분산, 에너지 사용량과 통신 오버헤드 및 지연 시간 제약 만족도 분석을 통해 성능을 검증한다.

본 논문은 다음과 같이 구성된다. 2장에서는 관련 연구, 3장에서는 시스템 모델, 4장에서는 제안 알고리즘을 다루었으며, 5장에서는 제안하는 알고리즘의 성능을 검증하였다. 마지막 6장에서는 결론과 향후 연구 계획을 다룬다.

2. 관련 연구

무선 네트워크에서 발생하는 많은 태스크를 빠르게 처리하기 위해 모바일 엣지 컴퓨팅에 대한 많은 연구가 진행되고 있다. 이는 컴퓨팅 서버를 사용자와 가까이 배치하여 에너지를 절약하고 대기 시간을 줄이며 모바일 디바이스의 처리 속도를 향상시킨다. 하지만 이러한 MEC 서버는 일반적으로 지상에 고정되어 있으며, 사용자의 요구에 따라 이동하거나 또는 변화하는 컴퓨팅 요구량에 유동적으로 대응할 수 없다 [3]. 이를 해결하기 위해 최근 UAV MEC를 추가적으로 이용하여 엣지 서비스를 제공하는 연구가 이루어지고 있다[4]. UAV는 비상 상황이나 태스크가 일시적으로 급증하는 상황에서 지상 사용자에게 안정적인 엣지 서비스를 제공할 수 있다[5]. 그러나 UAV MEC 서버는 지상 MEC와 달리 배터리 용량과 컴퓨팅 능력에 한계가 있어 효율적인 부하분산이 더욱 요구된다.

따라서 UAV의 제한된 에너지를 고려한 강화학습 기반의 오프로딩 기법[6,7]이나, 에너지 소모를 최소화하면서 모바일

디바이스의 태스크를 모두 수행할 수 있는 UAV의 최적 경로를 스케줄링하는 연구가 진행되고 있다[8]. 특히 이동성이 높은 차량환경에서 발생하는 태스크에도 유동적으로 대응하기 위해 UAV MEC를 사용할 수 있다[9]. 하지만 사용자가 매우 동적인 차량 환경에서는 태스크를 특정 MEC 서버에 오프로딩한 후, 해당 MEC 서버의 영역을 벗어나 다른 서버의 영역으로 이동하는 경우 서버간 태스크 마이그레이션을 수행해줄 필요가 있다[10,11]. 따라서 차량의 움직임, UAV의 에너지 상태 등을 고려하여 태스크 마이그레이션 기법에 대한 연구가 필요하다. 다시 말해서 UAV MEC의 배터리 용량에 한계가 있으므로 에너지 사용량과 통신 오버헤드를 고려한 마이그레이션 기법의 연구가 필요하며, 오프로딩 과정에서 로드 분산을 줄인 후 마이그레이션을 추가로 수행한다면 처리량 측면에서도 더욱 효율적인 시스템이라 할 수 있다.

따라서 본 논문에서는 유전 알고리즘 기반 오프로딩을 수행한 후 강화학습 기반의 마이그레이션을 추가적으로 수행하는 알고리즘을 제안한다.

3. 시스템 모델

본 논문에서는 Fig. 1과 같이 도심 내 환경에서 1개의 지상 MEC와 4개의 UAV MEC 서버로 구성된 환경을 가정하였다. 본 시스템은 일시적으로 트래픽이 급격히 증가되는 도심 지역의 출퇴근 시간 환경을 가정하였다.

UAV는 초기 위치에 고정되어 있으며, 지상으로부터 100m 높이에서 비행하고 있다고 가정한다. 지상 MEC와 UAV MEC 모두 엣지 서버로서의 동일한 역할을 하며, 지상 MEC와 UAV MEC 서버들은 무선 백홀(backhaul)망을 통해 통신하고, 모두 별도로 존재하는 하나의 컨트롤러와 연결되어 있다고 가정한다. 이때, 시스템 전체 처리량을 최대화하고 지연 시간 만족도를 높이기 위해 지상 MEC도 로드밸런싱의 대상으로 고려하지만 지상 MEC의 에너지 상태는 고려하지 않는다.




Fig. 1. System Model

타임 슬롯 t 에서 MEC $m, m \in M$ 의 로드 상태는 다음 Equation (1)과 같다.

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

L_m^t 는 타임 슬롯 t 일 때, MEC m 의 TASK 큐 길이를 나타내며, L_m^{\max} 은 MEC m 의 최대 TASK 큐 길이이다. 이를 이용하여 타임 슬롯 t 에서 모든 MEC 서버의 로드 평균을 다음과 같이 구할 수 있다.

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

따라서 타임 슬롯 t 에서 모든 MEC 서버들의 로드 분산과 편차는 각각 다음과 같다.

$$Load_{var}^t = \frac{1}{M} \cdot \sum_{m=1}^M (|\beta_m^t - LA^t|)^2 \quad (3)$$

$$Load_{dev}^t = \sqrt{Load_{var}^t} \quad (4)$$

UAV MEC의 에너지 사용량은 비행에 필요한 에너지, 컴퓨팅 에너지, 마이그레이션에 필요한 에너지가 모두 포함된다. 본 논문에서는 UAV가 초기 설정 위치에 고정되었다고 가정하였으므로, 제자리에 떠있는 에너지만 고려하여 다음과 같이 계산할 수 있다[1].

$$E_{fly}^{t,m} = \frac{\delta \cdot \tau}{2} \cdot \|H_m^t\|^2 \quad (5)$$

δ 는 중력 가속도를 의미하고, H_m^t 는 UAV의 비행 높이, τ 은 타임 슬롯의 길이를 의미한다.

UAV m 이 오프로딩된 TASK를 연산할 때 필요한 에너지는 다음과 같다.

$$E_{comp}^{t,m} = k \cdot \sum_{n=1}^{\psi_t^m} f_{n,m} \cdot \tau \quad (6)$$

ψ_t^m 는 타임 슬롯 t 에서 UAV m 에서 실행되는 TASK 개수이다. 이때, $f_{n,m}$ 은 TASK n 을 수행하기 위해 UAV m 에 요구되는 컴퓨팅 리소스, k 는 UAV의 CPU 유효 스위칭 전기 용량 값을 의미한다[1].

마지막으로 UAV MEC m 이 다른 UAV MEC m' 으로 TASK를 마이그레이션할 때 필요한 에너지는 주로 UAV의 전송 전력에 의해 결정되며, 다음 식과 같이 계산할 수 있다. 이때, $\psi_t^{m,m'}$ 은 다른 UAV로 마이그레이션되는 TASK 개수를 의미한다.

$$E_{mig}^{t,m,m'} = \sum_{n=1}^{\psi_t^{m,m'}} \left\{ p_{m,m'} \cdot \frac{d_{m,m'} \cdot i_n}{V_b} \right\} \quad (7)$$

$p_{m,m'}$ 은 MEC m 에서 m' 로 TASK를 마이그레이션 할 때 필요한 단위 시간 당 전송 전력을 나타내고, V_b 는 백홀 채널 전송 속도, $d_{m,m'}$ 은 MEC m 과 m' 의 거리를 나타낸다. i_n 은 TASK 크기, $\frac{d_{m,m'} \cdot i_n}{V_b}$ 는 무선 백홀 망을 통해 TASK를 전송하는데 걸리는 시간을 의미한다[1].

따라서 타임 슬롯 t 에서 UAV m 의 총 에너지 사용량은 다음과 같으며 ϕ_1, ϕ_2, ϕ_3 은 합이 1인 0과 1사이의 가중치 값을 의미한다.

$$E_{total}^{t,m} = \phi_1 \cdot E_{fly}^{t,m} + \phi_2 \cdot E_{comp}^{t,m} + \phi_3 \cdot E_{mig}^{t,m,m'} \quad (8)$$

따라서 4개 UAV의 총 에너지 소모량은 다음과 같다.

$$E_{total}^t = \sum_{m=1}^4 E_{total}^{t,m} \quad (9)$$

UAV의 통신 오버헤드는 다음과 같이 계산한다.

$$T^{trans} = \sum_{m=1}^M (i_n / s_{trans}^{m,m'}) \quad (10)$$

이때, $s_{trans}^{m,m'}$ 은 MEC m 과 m' 사이의 전송 속도를 의미한다.

본 논문에서는 유전 알고리즘 기반 오프로딩 기법과 강화학습 기반 마이그레이션 기법을 제안한다. 이 때, 하나의 UAV MEC에 너무 많은 TASK가 오프로드 되어 방전되는 상황을 막기 위해 오프로딩 시 UAV의 에너지 상태를 고려해 주어야 한다. 따라서 본 논문에서 제안하는 오프로딩 기법의 목적은 UAV의 에너지 사용량을 최소화하면서 로드밸런싱 하는 것이며, Equation (11)과 같이 표현할 수 있다.

마이그레이션 시에는 TASK를 전송하는데 걸리는 시간이 늘어나게 되면 UAV의 에너지 사용량에도 영향을 미치며, 처리 지연 시간이 늘어나게 되므로 통신 오버헤드를 고려해 주어야 한다. 따라서 본 논문에서 제안하는 마이그레이션 기법의 목적은 UAV의 통신 오버헤드를 최소화하며 로드 밸런싱 하는 것이며 이는 Equation (12)와 같이 나타낼 수 있다.

$$P1: \min (w \cdot Load_{dev}^t + (1-w) \cdot E) \quad (11)$$

$$P2: \min (w \cdot Load_{var}^t + (1-w) \cdot T_{trans}) \quad (12)$$

Table 1. Notations Used

Notation	Description
β_m^t	Load status of MEC $m, m \in M$ in time slot t
L_m^t	In time slot t , the task queue length of MEC $m, m \in M$
L_m^{\max}	Maximum task queue length of MEC $m, m \in M$
LA^t	Load average of all MEC servers in time slot t
$Load_{var}^t$	Load variance of all MEC servers in time slot t
$Load_{dev}^t$	Load deviation of all MEC servers in time slot t
$E_{fly}^{t,m}$	Flying energy of UAV MEC m in time slot t
δ	Acceleration of gravity
H_m^t	Flight height of UAV MEC m in time slot t
τ	Length of a time slot
$E_{comp}^{t,m}$	Energy required for computing tasks on UAV MEC m in time slot t
ψ_t^m	Number of tasks computed on UAV MEC $m, m \in M$ in time slot t
$f_{n,m}$	Computing resources required for UAV $m, m \in M$ to perform task n
k	CPU effective switched capacitance of UAV MEC
$E_{mig}^{t,m,m'}$	Energy required for migrating tasks from one UAV MEC m to another UAV MEC m'
$\psi_t^{m,m'}$	Number of tasks migrated from one UAV MEC m to another UAV MEC m' in time slot t
$P_{m,m'}$	Transmission power per unit time required to migrate tasks from MEC m to m'
V_b	Backhaul channel transmission rate
$d_{m,m'}$	Distance between MEC m and m'
i_n	Size of task n
E	Total energy consumption of UAV m in time slot t
E	Total energy consumption of all UAVs in time slot t
T^{trans}	Communication overhead of UAV MEC
$s_{trans}^{m,m'}$	Transmission rate between MEC m and m'

4. 제안하는 알고리즘

4.1 유전 알고리즘 기반 오프로딩 기법

본 논문에서는 유전 알고리즘(genetic algorithm)을 기반으로 오프로딩 대상과 비율을 결정하는 알고리즘을 제안한다. 시간에 따라 차량의 움직임과 태스크 발생이 매우 동적인 환경에서 해당 알고리즘은 최적화 문제를 해결하는데 적합하며, 유전 알고리즘의 특성 중 하나인 무작위성으로 인해 특정 MEC에 태스크가 집중되는 상황을 완화시킬 수 있다. 각 MEC는 자신의 커버리지에 속하는 차량들에게 자신들의 큐 상태, 에너지 상태 등의 정보를 보내고, 각 차량은 MEC로부터 받은 정보와 자신의 태스크 사이즈 및 위치 등을 고려하여 유전 알고리즘을 실행한다. 이를 바탕으로 차량은 UAV

MEC에 태스크를 오프로딩한다. 이 때, 적합도 함수는 다음과 같다.

$$fitness = \frac{1}{\alpha \cdot Load_{dev}^{nor} + (1 - \alpha) \cdot E} \quad (13)$$

$Load_{dev}^{nor}$ 은 MEC의 로드 편차를 정규화한 값이고, E 은 에너지 사용량을 정규화한 값이며 α 는 0과 1 사이의 가중치 값을 의미한다. 본 논문에서는 로드 분산과 에너지 사용량을 최소화하기 위해 적합도 함수를 Equation (13)과 같이 설정하여 이를 최소화 할 수 있는 오프로딩 비율을 찾아내고 오프로딩 한다.

4.2 강화학습 기반 마이그레이션 기법

본 논문에서는 유전 알고리즘 기반의 오프로딩을 수행한 후 추가적으로 Q-learning을 기반으로 태스크를 마이그레이션하는 기법을 제안한다.

상태(s), 행동(a), 보상(r)으로 구성되는 Q-learning은 Q 함수(Q function)를 기반으로 Q 값(Q value)이 가장 큰 행동을 선택하여 최적의 정책을 학습하도록 한다. 이때 Q 함수는 다음과 같다.

$$Q(s,a) = Q(s,a) + \alpha[r + \gamma \cdot \max_a Q(s',a') - Q(s,a)] \quad (14)$$

α 는 학습률(learning rate), γ 는 할인율(discount factor)이다. 이때, ϵ -탐욕적 알고리즘을 활용하여 ϵ 확률로 보상에 관계없이 무작위로 행동을 선택하도록 하였다[12].

본 논문에서의 Q-learning 알고리즘을 위한 상태(s), 행동(a), 보상(r)의 정의는 다음과 같다. $S_m^t = \{l_m^t, \beta_m^t, c_m^t\}$ 로 정의한다. l_m^t 는 MEC의 위치, β_m^t 는 MEC의 로드 상태를 의미하고, c_m^t 는 MEC에 오프로드 된 태스크 수를 의미한다. 시스템에 한 개의 지상 MEC와 $M-1$ 개의 UAV가 존재하므로, MEC의 상태 공간 집합을 나타내기 위해 $S = \{S_1^t, S_2^t, \dots, S_M^t\}$ 로 정의한다.

이러한 상태를 기반으로 컨트롤러는 행동을 결정하며, 행동 $A = \{a_{\psi_t^1}^1, a_{\psi_t^2}^2, a_{\psi_t^3}^3, \dots, a_{\psi_t^m}^m\}$ 으로 정의한다. 이는 각 MEC 별로 ψ_t^m 값을 결정하는 것으로, MEC m 에서 수행할 태스크 수와 종류를 결정한다. $\psi_t^{m,m'}$ 값은 MEC m 에 오프로드 된 총 태스크 수에서 Q-learning 알고리즘에 의해 결정된 ψ_t^m 값을 뺀 값으로 한다. 컨트롤러는 행동(a)을 취하고 보상 r 을 얻는다. 본 논문에서는 Equation (12)와 같이 UAV의 로드 분산을 줄이고 태스크를 마이그레이션 할 때 소모되는 통신 오버헤드를 줄이기 위해 학습을 진행한다. 따라서 보상은 $r = -\{w \cdot Load_{var} + (1-w) \cdot T_{comm}\}$ 과 같다.

5. 실험 및 성능 평가

제안 알고리즘의 성능을 평가하기 위해 $300m \times 300m$ 환경에서 1개의 지상 MEC와 4개의 UAV MEC가 배치된 상황에 대해 실험을 진행하였다. 지상 MEC는 해당 범위를 모두 서비스할 수 있다고 가정하였으며, UAV MEC의 커버리지 반경은 $200m$ 라고 가정하였다. 차량은 푸아송 분포로 발생시켰으며 태스크 사이즈는 $[100, 150]MB$ 내에서 무작위로 발생시켰다. 출퇴근 시간과 같은 교통이 혼

잡한 시간대임을 고려하여 한 타임 슬롯의 길이는 $60s$ 로 설정하였다. UAV의 초기 배터리 용량은 $10kJ$ 이라고 가정한다. 이때, Q-learning을 위해 학습률(learning rate)은 0.01 , 할인율(discount factor)은 0.9 그리고 ϵ 은 0.9 로 설정하였다.

본 논문에서 제안한 유전 알고리즘기반의 오프로딩 기법과 강화학습 기반의 마이그레이션기법의 성능 비교를 위해 “유전 알고리즘기반의 오프로딩을 수행한 후 마이그레이션은 하지 않는 기법”, “가장 가까운 MEC에 오프로딩 후 Q learning 기반의 마이그레이션을 수행하는 기법”, 그리고 “유전 알고리즘 기반의 오프로딩과 Q learning 기반의 마이그레이션을 모두 수행하는 기법”, 이렇게 총 3가지 기법을 비교하였다.

먼저 차량의 개수는 100대로 고정하고, 속도를 달리하여 실험을 진행하였을 때 결과는 Fig. 2-Fig. 5와 같다.

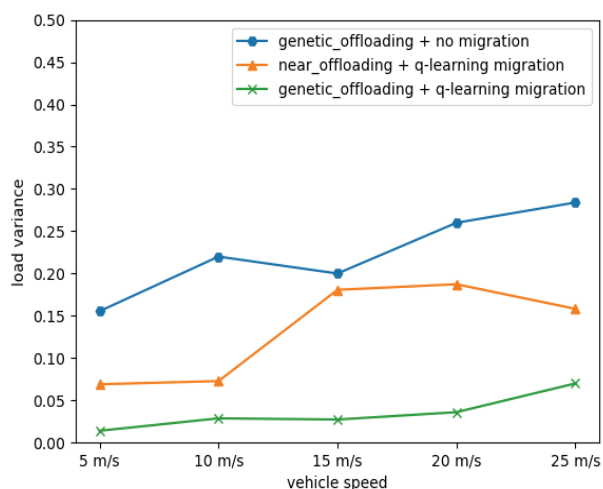


Fig. 2. Load Variance with Varying Vehicle Speeds

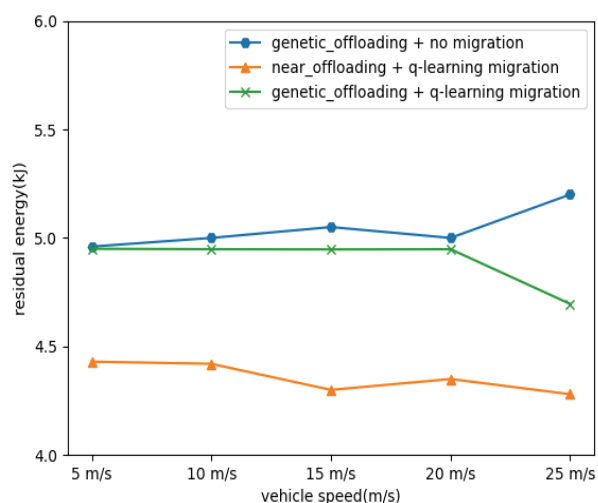


Fig. 3. Residual Energy with Varying Vehicle Speeds




Fig. 4. Communication Overhead with Varying Vehicle Speeds

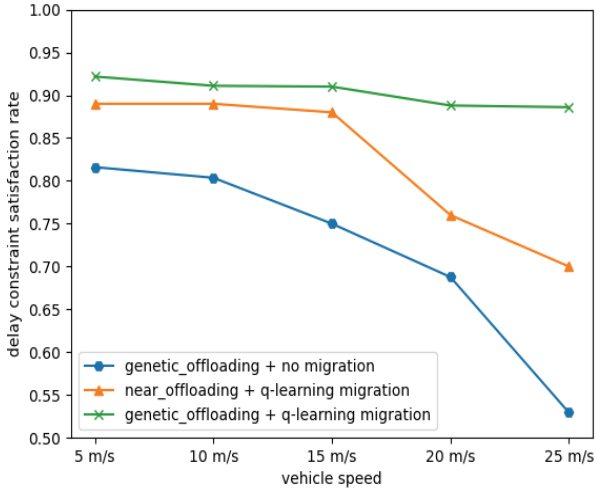


Fig. 5. Delay Constraint Satisfaction Rate with Varying Vehicle Speeds

“유전 알고리즘 오프로딩과 강화학습 마이그레이션을 모두 수행한 기법”의 경우 차량의 속도가 바뀌어도 분산에 큰 차이가 없으며 세 기법 중 분산이 가장 작은 것으로 보아 로드 밸런싱이 잘 이루어지고 있다는 것을 확인할 수 있다. 따라서 지연 시간 제약 만족도도 가장 높게 나타난다. 또한 “유전 알고리즘 기반 오프로딩 후 마이그레이션 하지 않는 기법”의 경우 MEC간 마이그레이션이 일어나지 않아 통신 오버헤드가 가장 작고 이로 인하여 잔여 에너지가 가장 많은 것을 확인할 수 있다. 그러나 마이그레이션이 이루어지지 않아 MEC서버들간 로드 편차가 마이그레이션을 진행하는 기법에 비하여 높으며, 지연 시간 제약 만족도는 가장 낮고 차량의 속도가 커질수록 가장 큰 폭으로 감소한다. “가장 가까운 MEC에 오프로딩 후 강화학습 마이그레이션을 수행하는 기법”의 경우 MEC의 로드 상황과 상관없이 차량에서 지리적으로 가장 가까운 MEC에게 태스크를 오프로딩함으로써

MEC 로드간 편차가 크다. 또한 후속작업으로 MEC간 로드 밸런싱을 위해 마이그레이션이 많이 진행되므로 에너지 소모 및 통신 오버헤드가 가장 크다.

다음으로 차량의 속도는 15m/s로 고정된 후, 차량의 개수를 달리하여 실험을 진행하였을 때 결과는 Fig. 6-Fig. 9와 같다.

“유전 알고리즘 기반 오프로딩 후 Q-learning기반의 마이그레이션을 수행하는 기법”의 경우에는 차량의 개수가 늘어나도 로드 분산에 큰 차이가 없으며, 로드 편차가 가장 낮고 지연시간 제약 만족도는 가장 높다. 또한 차량의 수가 늘어나면 처리해야 하는 태스크 수가 늘어나기 때문에 모든 기법의 잔여 에너지가 줄어들고 통신 오버헤드가 증가하게 되며, 지연 시간 제약 만족도는 감소하게 된다. 이때, “가장 가까운 곳에 오프로딩 후 마이그레이션 하는 기법”의 경우 마이그레이션이 상대적으로 많이 필요하기 때문에 에너지가 더 많이 감소하고 통신 오버헤드는 가장 큰 것을 확인할 수 있다.

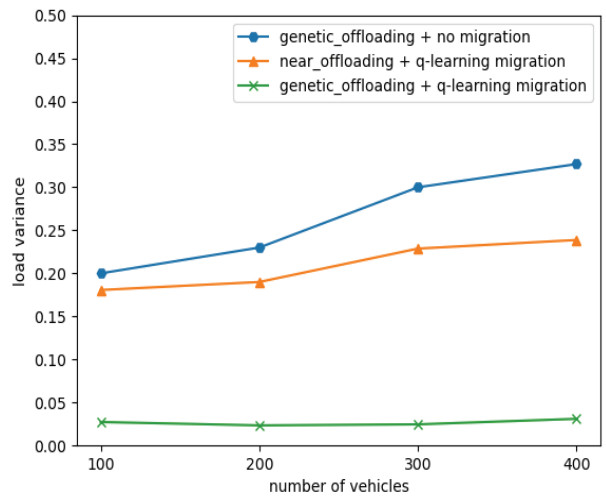


Fig. 6. Load Variance with Varying Number of Vehicles

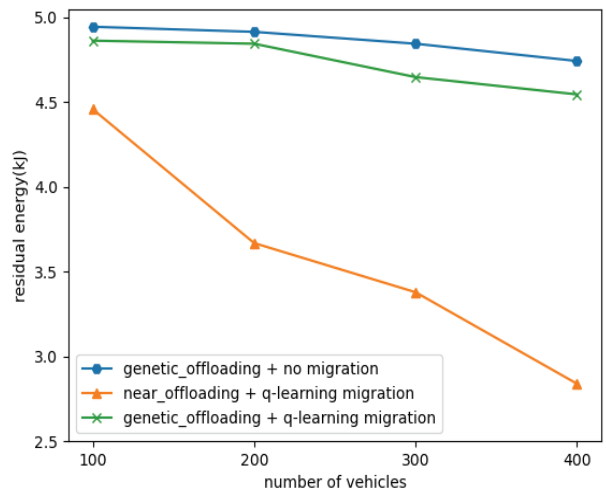


Fig. 7. Residual Energy with Varying Number of Vehicles




Fig. 8. Communication Overhead with Varying Number of Vehicles

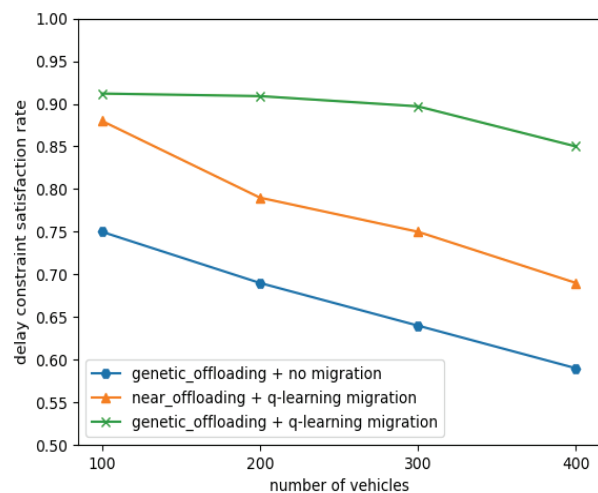


Fig. 9. Delay Constraint Satisfaction Rate with Varying Number of Vehicles

6. 결론

본 논문에서는 계산 집약적이고 지연 시간에 민감한 태스크가 발생하는 무선 네트워크 환경에서, 동적인 태스크 처리 요청을 효과적으로 처리하기 위한 기법을 제안하였다. 지상 MEC와 UAV들의 로드와 에너지 상태를 고려하여 유전 알고리즘 기반의 오프로딩 기법과 차량의 이동성 및 로드 분산, 통신 오버헤드를 고려한 강화학습 기반의 마이그레이션 기법을 제안하였다.

제안하는 알고리즘의 성능을 분석하기 위해 유전 알고리즘 기반 오프로딩만 수행하는 경우, 가장 가까운 곳에 오프로딩 후 강화학습 기반 마이그레이션을 수행하는 경우, 그리고 유전 알고리즘 기반 오프로딩과 강화학습 기반 마이그레이션을 모두 수행하는 기법을 비교해보았다. 이를 통해 두 가지를 모

두 수행하는 기법이 다른 두 기법보다 로드 밸런싱이 더 잘 되었다는 것을 확인할 수 있었다.

향후 연구에서는 차량의 이동성을 고려하여 지상 MEC 서버를 중심으로 UAV MEC 서버의 로드밸런싱을 고려하는 연구가 필요하며, UAV MEC 서버의 이동성이 존재하는 환경에서 UAV의 이동 경로를 추가적으로 고려한 환경에 대한 연구가 필요하다.

References

- [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] 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, BC. Canada, Nov. 2020.
- [3] Y. Wang, Z.-Y. Ru, K. Wang, and P.-Q. Huang, "Joint deployment and task scheduling optimization for large-scale mobile users in multi-uav-enabled mobile edge computing," *IEEE Transactions on Cybernetics*, Vol.50, No.9, pp.3984-3997, Sep. 2020.
- [4] Abrar, U. Ajmal, Z. M. Almohaimeed, X. Gui, R. Akram, and R. Masroor, "Energy efficient UAV-enabled mobile edge computing for IoT devices: A review," in *IEEE Access*, Vol.9, pp.127779-127798, 2021.
- [5] Y. Zeng, R. Zhang, and T. J. Lim, "Wireless communications with unmanned aerial vehicles: Opportunities and challenges", *IEEE Communications Magazine*, Vol.54, No.5, pp.36-42, May 2016.
- [6] L. Zhang et al., "Task offloading and trajectory control for UAV-Assisted mobile edge computing using deep reinforcement learning," *IEEE Access*, Vol.9, pp.53708-53719, 2021.
- [7] N. Zhao, Z. Ye, Y. Pei, Y. -C. Liang, and D. Niyato, "Multi-agent deep reinforcement learning for task offloading in UAV-assisted mobile edge computing," *IEEE Transactions on Wireless Communications*, Early Access, Mar. 2022.
- [8] H. Hu, X. Zhou, Q. Wang, and R. Q. Hu, "Online computation offloading and trajectory scheduling for UAV-enabled wireless powered mobile edge computing," *China Communications*, Vol.19, No.4, pp.257-273, Apr. 2022.

- [9] J. Wang, D. Feng, J. Zhu, and H. Huang, "Vehicular computation offloading in UAV-enabled MEC systems," *2022 IEEE 25th International Conference on Computer Supported Cooperative Work in Design (CSCWD)*, pp.1071-1076, Hangzhou, China, May 2022..
- [10] 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, Chengdu, China, Apr. 2021.
- [11] C. Gong, L. Wei, D. Gong, T. Li, and F. Feng, "Energy-efficient task migration and path planning in UAV-enabled mobile edge computing system," *Hindawi Complexity*, Vol.2022, pp.1-16, Apr. 2022.
- [12] N. I. Mowla, N. H. Tran, I. Doh, and K. Chae, "AFRL: Adaptive federated reinforcement learning for intelligent jamming defense in FANET," *Journal of Communications and Networks*, Vol.22, No.3, pp.244-258, Jun. 2020.



신 아 영

<https://orcid.org/0000-0001-6809-3942>
e-mail : ayoung7@sookmyung.ac.kr
2022년 숙명여자대학교 IT공학과(학사)
2022년~현 재 숙명여자대학교
IT공학과 석사과정
관심분야: 지능형 시스템, IoT, Edge Computing



임 유 진

<https://orcid.org/0000-0002-3076-8040>
e-mail : yujin91@sookmyung.ac.kr
2000년 숙명여자대학교 전산학과(박사)
2013년 일본 Tohoku University,
Department of Information Sciences(박사)
2004년 ~ 2015년 수원대학교 정보미디어학과 부교수
2016년 ~ 현 재 숙명여자대학교 IT공학과 교수
관심분야: 지능형 시스템, IoT, Edge Computing