

강화학습을 이용한 UAV-EDGE 협업 태스크 오프로딩 방안 연구

김기태, 홍충선*

경희대학교 컴퓨터공학과

glideslope@khu.ac.kr, *cshong@khu.ac.kr

A Study on UAV-Edge Joint Task offloading Scheme using Reinforcement Learning

Kitae Kim, Choong Seon Hong*

Kyung Hee University

요약

UAV(Unmanned Aerial Vehicle)는 이동이 가능하며 카메라와 센서, 컴퓨팅자원, 통신기기를 탑재할 수 있다는 장점을 가지고 있다. 따라서 5세대 통신에서 UAV가 중요한 역할을 할 것이라고 예측되고 있다. 이러한 통신기술과 UAV의 장점을 결합하여 재난현장에서의 신속한 대처가 가능하며 공연장과 스포츠 경기장과 같은 트래픽 수요가 많은 곳에서 이동 기지국으로 활용 될 수 있다. 또한 탑재된 카메라나 센서를 활용해 다양한 데이터 수집 및 수집된 데이터 기반 서비스 제공이 가능하다. 하지만 이러한 서비스는 빅 데이터 처리와 머신러닝과 같은 고성능의 컴퓨팅 능력이 필요하며 컴퓨팅 자원의 한계가 있는 UAV에서 이러한 서비스를 홀로 처리하기에는 무리가 있다. 따라서 본 논문에서는 태스크 발생 시 다수의 엣지 서버와 UAV의 현재 상태를 고려하여 태스크 수행을 위한 엣지-UAV 매칭 및 최적의 UAV의 위치선정에 대해 제안한다.

I. 서론

고 대역폭, 저 지연 서비스를 제공할 수 있는 5세대 통신의 등장과 다양한 스마트 디바이스, IoT 센서, 드론과 같은 다양한 기기의 등장으로 수 많은 데이터와 이를 이용한 다양한 어플리케이션이 등장하였다. 이러한 어플리케이션들은 가상현실과 증강현실, 머신러닝, 빅 데이터처리와 같은 고성능 컴퓨팅 자원이 필요하며 스마트폰이나 무인항공기와 같은 기기에서 실행되기에는 무리가 있다. 이러한 문제를 해결하기 위하여 기지국이나 AP와 같은 네트워크의 가장자리(Edge)에 컴퓨팅 자원을 위치시켜 모바일 유저나 IoT 센서들이 인접한 노드의 컴퓨팅 자원을 활용할 수 있는 MEC(Mobile Edge Computing) 기술이 등장하였다[1].

이동 가능한 무인 항공기는 카메라 뿐 만 아니라 다양한 센서와 통신 기기를 탑재할 수 있다는 점에서 큰 주목을 받고 있다. 이러한 무인 항공기는 앞서 언급하였던 엣지 노드가 될 수 있으며 무인 항공기를 이용해 재난 현장에서의 신속한 대처와 통신 수요량이 많은 지역에서 이동식 기지국으로서 활용이 가능하다[2]. 특히 이동하면서 다양한 사진이나 영상과 같은 다양한 데이터 수집을 및 분석을 통하여 이상 상황 탐지, 농작물 성장추이, 기상 예측 등과 같은 데이터 기반 서비스 제공이 가능하다. 하지만 앞서 언급하였듯이 이러한 데이터 분석은 빅 데이터 처리 기술이나 머신러닝과 같은 고성능 컴퓨팅 자원을 요구하며 자원의 한계가 있는 UAV에서 이러한 태스크를 수행하기에는 무리가 있다. 따

라서 본 논문에서는 태스크 발생 시 Task와 UAV의 위치, 상태에 따른 Task-UAV 매칭과 엣지 노드와 태스크 수행 협업을 위한 최적의 엣지 노드 선택과 이를 위한 UAV의 최적의 위치 선정에 대한 연구를 진행하였다.

II. 시스템 모델




그림 1 . 시스템 모델

본 논문에서는 그림1과 같이 4개의 엣지 노드와 무작위의 위치에 배치된 4대의 UAV를 고려한다. 여기서 모든 UAV

는 고도는 일정한 것으로 가정한다. Task 또한 무작위의 위치에서 발생한다. UAV의 상태로는 각각의 현재의 위치 값과 배터리 상태를 고려한다. 엣지 서버에서는 현재의 유휴 자원상태를 고려한다. Task는 Task의 크기와 Task를 실행하는데 필요한 CPU Cycle, 그리고 Task의 타입을 고려한다. 태스크는 2가지의 타입으로 구분되며 Data Rate와 실행 시간을 보장이 필요한 Task(1)와 그렇지 않은 Task(0)로 나뉜다.

종류	변수	설명
UAV	B_{UAV}	현재 배터리(J)
	L_{UAV}	UAV 현재 위치
Task	T_{cpu}	수행에 필요한 CPU Cycle
	T_{size}	Task Input 사이즈
	T_{type}	Task 타입(0,1)
	$T_{location}$	Task 발생위치
Edge	E_{cpu}	CPU 사용률

표 1 . UAV-TASK-EDGE에서 고려되는 변수

UAV 에너지 소비 모델

랜덤한 위치에서 Task가 발생하면 UAV는 Task의 위치에 가서 Task 수행을 위한 데이터 수집 후 함께 협업 할 엣지 서버의 위치까지 비행해야 한다. 이 때 소비되는 UAV의 에너지 모델[3]은 아래와 같다.

$$E = \frac{p^{\min} d}{v\eta}$$

수식 1. 이동 거리에 따른 UAV 에너지 소비 모델

수식1.에서 v 와 d 는 각각 UAV의 속도와 총 비행 거리를 나타내며 η 은 Power Efficiency를 나타낸다. p^{\min} 은 UAV가 움직이기 위한 최소한의 에너지를 나타내며 아래 수식2와 같이 정의된다.

$$p_{\min} = (v_1 + v \sin\beta)T$$

수식 2. UAV 추진을 위한 최소 에너지

여기서 T 는 추진하기 위한 힘을 나타내며 수식3과 같이 정의된다.

$$T = mg + f_d$$

수식 3. UAV의 추진력

m 은 UAV의 무게 g 는 중력가속도 f_d 는 공기에 의한 항력을 나타낸다. 수식2에서 v_1 은 추진력 T 를 속도로 수식 4로 정의 된다.

$$v_1 = \frac{2T}{qr^2 \rho \sqrt{(v \cos\beta)^2 + (v \sin\beta + v_1)^2}}$$

수식 4. 추진력 T를 위한 속도

통신 및 컴퓨팅 모델

최적의 위치에서 UAV로부터 엣지 노드에게 태스크 오프로딩을 위하여 UAV-Edge 간 Uplink Data Rate를 측정한다. 본 논문에서의 Data Rate[4]는 아래와 같이 측정된다.

$$DataRate = B \log_2 \left(1 + \frac{pc}{\sigma^2 + I} \right)$$

수식 5. UAV-Edge간 Data Rate

수식2.에서 B 는 대역폭, p 는 transmission power, c 는 channel gain, σ^2 는 noise power를 나타낸다. 수식2의 Data Rate를 이용해 엣지로의 오프로딩 시 컴퓨팅 소요시간은 아래의 수식6과 같이 모델링 될 수 있다.

$$T = \frac{T_{cpu}}{A_{cpu}} + \frac{T_{size}}{DataRate}$$

수식6. 총 컴퓨팅 소요시간

총 컴퓨팅 소요시간은 Data Rate에 따른 엣지에서의 태스크 인풋에 대한 전송시간과 태스크 수행을 위해 엣지에서의 Task 수행시간의 합으로 정의 된다. 따라서 A_{cpu} 는 엣지에서 태스크 수행을 위해 할당된 CPU Cycle를 의미한다.

III. 제안사항

본 논문에서는 Q-Learning을 이용하여 Task의 요구에 맞게 UAV의 에너지 소비량과 Uplink Data Rate에게 적절한 가중치를 주어 적절한 위치에서의 Task의 요구를 만족시킬 수 있는 오프로딩 기법을 제안한다.

Deep Q-Learning

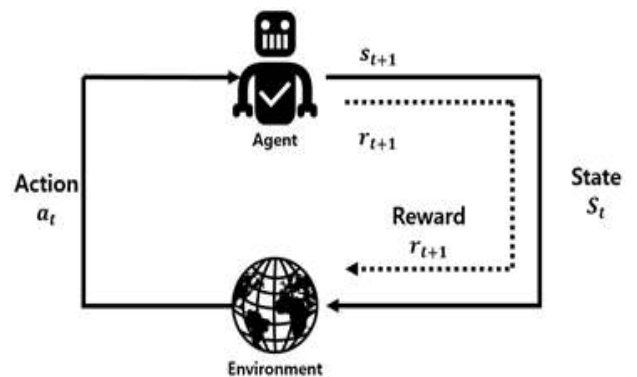


그림 2. Q-Learning

강화학습의 한 종류인 Deep Q-Learning[5]은 학습 에이전트(Agent)가 상태를 관찰 후 어떠한 행동(Action)을 취함

으로써 그에 따른 보상(Reward)를 받는다. 이 과정을 통하여 에이전트는 미래의 보상 값을 극대화하기 위한 의사결정을 학습한다. 따라서 Q-Learning에는 보상을 어떻게 주느냐가 가장 중요하다. 이러한 Q-Learning은 2015년 등장했던 인공지능 바둑 기사인 알파고에 적용된 학습 알고리즘이기도 하다. 본 논문에서 Q-Learning을 위한 상태는 앞서 표 1에서 소개한 모든 UAV의 상태와 위치, Task의 위치 및 특성, 협업 가능한 모든 Edge Server의 상태를 통해 계산된 에너지 소비량과 Data Rate, 오프로딩 시간을 통해 정의된다. 이러한 상태를 관찰한 에이전트는 어떠한 UAV가 Task를 수행하여 어떤 엣지와 협업하는지 결정하는 행동(Action)을 취하여 행동에 상응하는 보상함수를 받게 된다. 적절한 보상을 위하여 본 논문에서의 보상함수는 앞서 II에서 실제 Task의 요구사항을 만족시키는데 영향을 미치는 UAV에너지 소비 모델과 통신·컴퓨팅 모델에 따라서 보상함수가 계산된다. Task의 2가지 특성에 따라서 만족시켜야 하는 요구사항이 다르므로 Task의 특성에 따라 에너지 소비 모델과 통신·컴퓨팅 모델에 가중치 α, γ, δ 를 정하여 보상함수 계산을 한다. 가중치는 Task의 종류에 따라 실행시간이 보장되어야 하는 서비스의 가중치를 높이고 다른 가중치에 대해서는 낮은 가중치를 주는 방식으로 적용한다. 공통적으로 보상함수는 UAV 이동을 위한 에너지 소비를 줄이며 통신효율이 좋은 위치를 찾아내는 것을 목표로 한다.

$$Reward = \alpha \frac{1}{E} + \gamma \frac{DataRate}{\delta T}, \quad \alpha + \gamma + \delta = 1$$

수식 7. 보상함수

이러한 보상함수를 통해 학습이 진행된 에이전트는 Task가 발생함에 따라 앞서 언급한 상태를 Input으로 하여 어떠한 드론이 Task를 받아 어떠한 엣지 노드와 협업을 했을 때 가장 보상 값이 클지 계산하는 방법으로 최적의 정책을 학습한다. 알고리즘의 Output으로는 Task를 수행할 드론과 협업할 Edge 노드 그리고 Edge 노드와 협업하기 위하여 이동해야할 위치가 나온다.

IV. 시뮬레이션

변수	값
ρ	$1.225kg/m^3$ [6]
f_d	$9.6998N$ [6]
q	4 [6]
r	$0.254m$ [6]
η	70% [6]
v	$1.49m/s$ [6]
B	[1,10]MHz
p	[0.5,1]W
σ^2	$2 \times 10^{-13} W$
c	$127 + 30 \times \log d$

표 2. 시뮬레이션 변수

표2는 II절의 수식들을 계산하기 위한 변수를 나타낸다. 위치별 상이한 통신 상태를 위하여 Data Rate 계산을 위한 변수들은 일정한 범위 내에서 임의의 값을 가지게 된다. 시뮬레이션을 위해 파이썬과 강화학습을 위하여 Tensorflow를 이용하였다. 시뮬레이션을 위하여 200X200의 2차원 평면을 만들어 4개의 엣지 서버와 4대의 임의의 위치의 드론, 1개의 임의의 Task를 발생시켰다.

시뮬레이션 결과

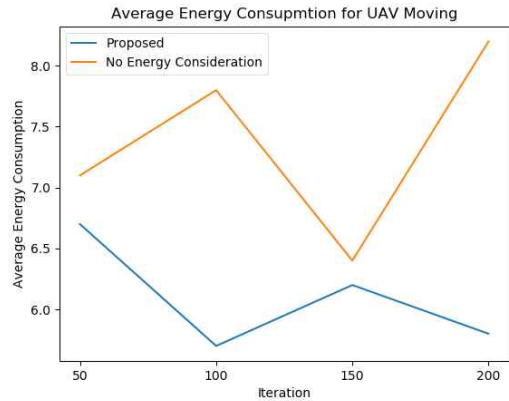


그림 3. UAV의 평균 이동 에너지 소비량

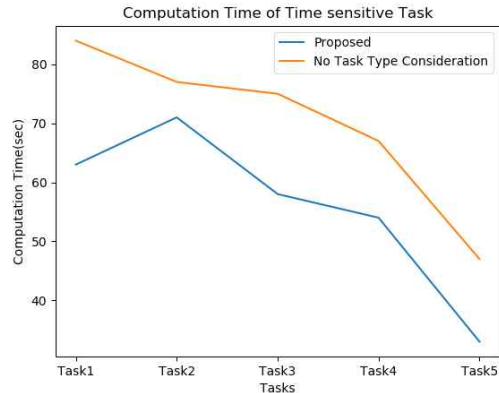


그림 4. Task에 따른 컴퓨팅 타임

그림3은 본 논문에서 제시한 알고리즘에 대해 UAV의 에너지 소비량을 고려하지 않았을 때와 고려했을 때 평균 에너지 소비량을 비교하였다. Task의 컴퓨팅 요구를 맞추는 것도 중요하지만 UAV의 배터리도 한계가 있기 때문에 두 가지를 동시에 고려하는 것이 중요하다. 에너지 소비량을 고려하였을 때 UAV가 Task로의 이동 이후에 엣지까지 이동하는 평균 에너지가 적음을 알 수 있다. 그림4는 동일 Task 5개에 대하여 실행시간의 보장이 필요한 Task와 그렇지 않은 태스크를 고려하지 않았을 때와 고려하였을 때의 평균 컴퓨팅 시간을 비교하였다. Task 타입을 구별하였을 때 큰 가중치가 적용이 되어 컴퓨팅 자원이 풍부하고 적절한 위치에서의 오프로딩이 이뤄지기 때문에 컴퓨팅 시간이 더 적게 걸리는 것을 확인 할 수 있었다.

V. 결론

본 논문에서는 Task 발생 시 UAV-Edge간의 협업을 위한 강화학습 기반의 Task 오프로딩 기법을 제안하였다. 드론이 어느 정도의 컴퓨팅 자원을 제공 할 수 있지만 컴퓨팅 자원의 제약과 배터리 문제로 드론 또한 엣지의 컴퓨팅 자원과의 협업을 필요하다. 이 때 드론의 에너지 문제와 컴퓨팅을 가장 잘 수행할 수 있는 주변의 엣지 서버를 찾아 가장 효율적인 위치에서 오프로딩을 하기 위하여 강화학습을 적용하였다. 향후에는 다수의 Task가 동시에 일어났을 때의 처리와 UAV-UAV간 협업, 다수의 엣지 서버와의 협업을 고려하여 연구를 진행 할 계획이다.

ACKNOWLEDGMENT

이 논문은 2019년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2019-0-01287, 분산 엣지를 위한 진화형 딥러닝 모델생성 플랫폼). 또한 이 논문은 2019년도 정부(과학기술정보통신부)의 재원으로 정보통신기술진흥센터의 지원을 받아 수행된 연구임(No.2015-0-00567, 유무선 통합 네트워크에서 접속 방식에 독립적인 차세대 네트워킹 기술 개발)*Dr. CS Hong is the corresponding author

참 고 문 헌

- [1] 박준민." Cloud to Rain, 엣지 컴퓨팅이 가져올 변화," 정보통신산업진흥원, pp. 4-5, 2018
- [2] Sarder Fakhrul Abedin, Md. Golam Rabiul Alam, Choong Seon Hong, "Learning Based Intelligent IoT Task Offloading and Resource Allocation in UAV-assisted Fog Network", 2017년 한국컴퓨터종합학술대회 논문집
- [3] Momena Monwar, Omid Semiari, Walid Saad "Optimized Path Planning for Inspection by Unmanned Aerial Vehicles Swarm with Energy Constraints", arXiv1808.06018, Aug, 2018
- [4]Min Chen, Yixue Hao, "Task Offloading for Mobile Edge Computing in Software Defined Ultra-Dense Network", IEEE JOURNAL ON SELECTED AREAS IN COMMUNICATIONS, VOL36, NO3, March 2018
- [5] "Q-Learning",<https://en.wikipedia.org/wiki/Q-learning>
- [6] J. K. Stolaroff, C. Samaras, E. R. O'Neill, A. Lubers, A. S. Mitchell, and D. Ceperley, "Energy use and life cycle greenhouse gas emissions of drones for commercial package delivery" Nature Communications vol. 9, no. 409, pp. 1 - 13, February 2018.