

논문 2025-62-3-7

UAV 기반 무선전력전송 네트워크에서 강화학습을 활용한 IoT 네트워크 활성화 알고리즘

(IoT Network Activation Algorithm in UAV Assisted Wireless Power
Transmission Networks using Reinforcement Learning)

김 대 솔*, 손 민 정**, 하 서 영**, Muy Sengly**, 이 정 룬**

(Daesol Kim, Minjung Son, Seoyeong Ha, Muy Sengly, and Jungryun Lee[©])

요 약

Internet of Things(IoT) 기기들의 배터리 사용을 최적화하여 에너지 낭비를 줄이고, 기기의 수명을 극대화 하는것은 IoT 네트워크에서 중요한 연구 주제 중 하나이다. 본 연구에선 무인항공기 (Unmanned Aerial Vehicle, UAV)가 지원되는 Simultaneous Wireless Information and Power Transfer (SWIPT) Radio Frequency (RF) 통신기술 기반의 무선전력전송 IoT 네트워크에서 비활성화된 IoT 단말을 효율적으로 활성화시키는 알고리즘에 관한 연구를 수행한다. SWIPT RF 통신기술 기반의 무선전력전송 UAV을 활용해 IoT를 충전함을 전제로 하여 충전 역할을 해주는 UAV의 사용 전력을 최소화하는 저전력 시스템을 구축하기 위해 UAV의 호버링 지점 및 비행경로를 최적화해주는 강화학습을 설계했다. Epsilon Decay 정책과 Replay Memory 기술이 활용된 Q-learning 알고리즘을 적용하여 각 클러스터간을 이동하여 UAV의 비행경로를 최종적으로 결정하는 알고리즘을 제시한다. 시뮬레이션 결과, 에이전트가 효과적으로 학습되었음을 확인할 수 있다.

Abstract

Optimizing the battery use of Internet of Things (IoT) devices to reduce energy waste and maximize the lifespan of devices is one of the important research topics in IoT networks. In this study, we present an algorithm that efficiently activates deactivated IoT terminals in wireless power transmission IoT networks based on simple wireless information and power transfer (SWIPT) radio frequency (RF) communication technology supported by Unmanned Aerial Vehicle (UAV). Based on SWIPT RF communication technology, wireless power transmission UAV is used to charge IoT, and reinforcement learning that optimizes UAV's hovering point and flight path was designed to build a low-power system that minimizes the power used by UAVs that serves as a charging role. By applying the Epsilon Decay policy and the Q-learning algorithm utilizing Replay Memory technology, we present an algorithm that finally determines the flight path of UAV by moving between clusters. As a result of the simulation, it can be confirmed that the agent has been learned effectively.

Keywords : UAV, Reinforcement learning, AI, Replay memory, SWIPT

*학생회원, **비회원, 중앙대학교 전자전기공학부(School of Electrical and Electronics Engineering, Chung-Ang University)

[©] Corresponding Author(E-mail : jrlee@cau.ac.kr)

※ 이 논문은 2024년도 정부(과학기술정보통신부)의 재원으로 한국연구재단 현장연계 미래선도인재양성 지원사업 (No. 2022H1D8A3037386)과 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터사업(IITP-RS-2024-00436248, 50)의 연구결과로 수행되었음.

Received ; October 24, 2024

Revised ; November 24, 2024

Accepted ; November 27, 2024

I. 서 론

인터넷을 통해 기기들을 연결하여 네트워크를 형성, 원격으로 사물을 모니터링하거나 관리하는 사물 인터넷(IoT, Internet of Things) 기술은 기기나 내장된 소프트웨어의 크기가 커질수록 시스템 자체의 자원 소모량과 비용이 커진다는 제약사항으로 인하여 저용량, 저전력을 지향하는 방향으로 발전하고 있다^[1]. 이에 따라 저전력 IoT 기기들의 배터리 사용을 최적화하여 에너지 낭비를 줄이고, 기기의 수명을 극대화하는 것 또한 중요한 연구 주제 중 하나로 자리잡았다. 또한, 이런 저전력 IoT 기기들의 대다수가 휴대성을 같이 띠는 점에서 이들을 어떻게 충전하고 네트워크에 대한 연결성을 유지할 수 있는지에 관해서도 연구가 진행되고 있다.

최근 이에 대한 해결책으로써 무인항공기(UAV, Unmanned Aerial Vehicle) 기반 무선전력전송(Wireless Power Transfer) 네트워크 기술이 고려되고 있다. 무선전력전송 기능을 탑재한 무인항공기(UAV, Unmanned Aerial Vehicle)가 SWIPT와 같은 기술을 통해 IoT 단말에게 에너지를 전송하고 동시에 데이터를 송수신함으로써 IoT 단말들의 수명을 늘리고 IoT 네트워크 유지 비용을 절감하는데 기여할 수 있다^[2]. 이때, 한정된 UAV의 배터리를 효율적으로 이용하기 위해서는 UAV의 이동 경로를 조정하여 그 소모량을 최적화하는 과정을 거쳐야 한다. 따라서 IoT 단말들의 위치를 파악하고 이동 경로 설정을 위한 알고리즘 등의 개발이 중요하다^[3, 4].

본 연구에서는 Python 기반 시뮬레이션 방법을 활용하여 IoT 네트워크에서 IoT 단말들을 충전 및 재연결을 시키기 위한 IoT 단말들의 무선 충전 효율을 높이기 위한 UAV의 호버링 지점 및 비행 경로 설정 강화학습 설계에 관한 연구를 수행한다.

관련된 선행 연구로 Lagrange Dual Method를 사용한 최적의 충전 시간을 구하는 모델에 대한 연구가 있다^[5]. 다수의 IoT 단말을 충전하는 과정에서 Lagrange Dual Method를 이용하여 IoT 단말의 충전을 위해 UAV가 머물러야 하는 최적의 위치, 즉 중간 지점들을 계산한 후, 이후 지점들을 연결하고 최적의 충전 시간을 구하는 방식으로 경로를 설정하였다.

타 연구 논문에서는 하나의 UAV가 정해진 고도로 비행하는 것을 가정하여 IoT 단말들이 전달받는 에너지량을 최대화하는 2D 경로를 제안하였으며^[6], 이를 기반으로 진행된 연구^[7]에서는 IoT 단말들이 전부 직

선으로 배치되었을 때 모든 단말들이 전달받는 최저 에너지량을 최대화하는 경로를 설정하였다.

II. 시뮬레이션 환경

SWIPT(Simultaneous Wireless Information and Power Transfer)는 하나의 Transmitter에서 방사하는 통신 신호를 이용하여, 무선으로 전력과 정보를 전송하는 기술이다^[8]. 본 연구의 시뮬레이션 환경에서의 UAV의 충전 빔으로부터 GU가 초당 공급받는 전력은 FSPL(Free Space Propagation Loss)에 따른 전파손실을 고려한다. FSPL은 무선통신 시스템에서 송신기와 수신기 사이의 거리와 주파수에 따른 전파 손실을 설명하는 모델이다. 이는 송, 수신 간에 장애물이 없는 LOS 환경하에서 수신 신호의 강도를 예측한다. 해당 모델로 통신 시 전파의 에너지 손실은 다음과 같이 정의된다^[9].

$$FSPL(x, p)[dB] = 20 \log_{10} \frac{4\pi f d(x, p)}{c} \quad (1)$$

따라서 본 UAV의 충전 빔으로부터 GU가 초당 공급받는 전력은 다음과 같다.

$$W[W] = 1 \times 10^{\frac{P_{TX} - 20 \log_{10} \left(\frac{4\pi f d(x, p)}{c} \right)}{10}} \times 1000 \quad (2)$$

$x = (x, y, H)$ 는 UAV의 위치를 나타내고, $p = (\bar{x}, \bar{y}, 0)$ 는 지상의 IoT 단말을 나타낸다. $d(x, p)$ 는 x 와 p 사이의 직선거리를 나타내는 함수이고, P_{TX} 는 송신기 전력, f 는 RF 신호의 중심 주파수, c 는 빛의 속도를 나타낸다.

본 연구에서 사용되는 UAV는 IoT 단말을(이하 Ground User, GU) 충전하기 위해 사용되는 충전 빔은 IoT와 UAV 사이의 고도각인 $\theta(x, p)$ 에 의해 정의된다.




그림 1. UAV의 충전 빔모델

Fig. 1. Model of UAV charge beam.

$$\theta(x, p) = \frac{180}{\pi} \cdot \tan^{-1} \frac{H}{d \cdot x_{proj, p}} \quad (3)$$

$x_{proj}(x, y, 0)$ 는 $H = 0$ 인 평면에 정사영한 UAV의 좌표를 나타낸다.

시뮬레이션 환경은 Python을 이용하여 구현되었으며, 50 m x 50 m크기의 정사각형 공간에 10개의 GU를 무작위로 배치하고, 고도 10 m에서 UAV가 비행하는 가상 IoT네트워크를 가정하였다. 이 때, z축에 해당하는 건물과 지상의 경사 등은 별도로 고려하지 않았다.

표 1. 시뮬레이션 환경 변수
Table 1. Simulation Parameters.

Category	Contents
Number of GU	10
Size of grid area	50 m × 50 m
Altitude of UAV	10 m
Moving power of UAV	1 W/s
Transmit power of UAV	1.585 W
Maximum of Beam angle	60°
Speed of UAV	2.5 m/s

표 1은 시뮬레이션에 적용한 환경변수(parameter)이다. IoT 네트워크 환경 구현에서 사용한 격자 환경의 크기(Size of grid area), GU의 개수가 표기되어있다. 또한, UAV-GU간의 전력공급량 및 UAV의 비행시간을 계산하기 위해 표 1에 표기된 바와 같이 10 m의 UAV의 고도, 1 W/s의 UAV의 초당 이동 소모전력, 1.585 W의 단위 전력공급량, 60°의 충전 빔 각도, 2.5 m/s의 UAV의 속도 등 5가지가 정의되었다.

III. IoT네트워크 환경에서의 UAV 호버링 지점 및 비행경로 최적화 위한 강화학습 설계

상술된 바와 같이 본 논문의 IoT 네트워크 환경에서는 전력공급 목표 단말기인 GU가 무작위로 분포되어 있고, 전력공급원인 UAV의 충전 빔 안에 들어오면 초당 전력공급량은 식 (2)에 의해 결정된다. UAV는 전력공급을 위해 한 지점(이하 호버링 지점)에 멈추어야 하고, 호버링 지점-GU 간의 거리와 전력공급량은 반비례하는 관계에 있어 소모전력 효율화를 위해 배터리 잔량 기반의 최적의 호버링 지점을 계산할 필요가 있다. 이를테면, 호버링 지점과 GU의 거리가 1 m 이내일때와

17 m 일때는 초당 전력공급량에 91%의 차이가 발생한다. 따라서 배터리 잔량 기반의 호버링 지점 계산이 필요하다. 또한, 비행경로의 거리를 줄임으로써 소모전력 효율화를 달성할 수 있다.

본 연구에서는 배터리 잔량 기반의 최적의 호버링 지점 계산과 비행경로 거리를 최소화하는 소모전력 최적화 문제를 해결하기 위해 큐-러닝 기법의 강화학습의 사용을 제안한다. 제안하는 큐-러닝 프레임워크의 에이전트(agent), 상태(state), 행동(action) 및 보상(reward)은 다음과 같이 정의된다.

1) 에이전트: 본 연구에서는 전력공급원인 UAV가 에이전트로 간주된다. 에이전트는 환경을 관찰하고 행동을 선택하여 나온 여러 가지 경험을 통해 보상을 최대화할 수 있는 최적의 행동을 결정한다.

2) 상태: 평면 좌표계로 표현되는 호버링 지점의 2차원 위치 정보와 GU의 배터리 잔량을 상태로 정의한다. (x_i, y_i, P_N) 은 각각 x좌표, y좌표, N번째 GU의 배터리 잔량을 의미하는 UAV의 호버링 지점 위치 i 의 상태를 나타낸다. 따라서 상태는 다음과 같이 정의된다.

$$s_i(t) = (x_i(t), y_i(t), P_N(t)) \quad (4)$$

3) 행동: 에이전트가 선택가능한 행동으로는 식 (5)과 같이 충전 지점(Charging Point, CP)의 인덱스와 UAV의 호버링 시간에 따라 분류된다.




그림 2. 충전 지점
Fig. 2. Charge points.

$$a_{uav} = [possible\ CP's, time\ of\ hovering] \quad (5)$$

충전 지점은 호버링 지점이 될 수 있는 후보군이다. 에이전트가 호버링 지점으로 선택할 수 있는 지점은 충전 지점 뿐이며, 그 외의 지점은 선택할 수 없는 제약이 있다. 그리고 에이전트의 행동 선택은 식 (6)과 같이

랜덤숫자 N 과 ϵ 에 의해 결정되는 ϵ decay 정책에 따라 결정된다.

$$a_{uav}^n = \begin{cases} Q_{\max} & \epsilon < N \\ random\ value & \epsilon \geq N \end{cases} \quad (6)$$

에이전트가 선택 가능한 행동의 인덱스는 t_{hovmax} 가 충전 빔에서 UAV로부터 가장 멀리 떨어진 GU의 충전 소요시간, t_{hov} 가 실제 호버링 시간, 그리고 N 이 충전 지점의 인덱스 일 때, 식 (7)와 같이 정의할 수 있다.

$$S(t_{hovmax}(N-1) + t_{hov}) \quad (7)$$

4) 보상: 에이전트의 전력소모량은 호버링 지점에 머무르는 시간과 비행경로에 따른 비행시간에 비례한다. 배터리 잔량 기반의 호버링 지점과 비행경로 최적화를 위해 에이전트의 행동에 따라 받는 보상을 설계하였다. 환경에서 행동 정보에 따라 각 에이전트는 다음의 스칼라 값으로 보상을 받을 수 있다. 보상은 $R_{t+1, time}$, $R_{t+1, complete}$, $R_{t+1, visited}$, $R_{t+1, efficiency}$ 로, 총 4가지 요소가 적용된다. GU에게 충전량 데이터를 받으며 충전하는 시간과 UAV의 이동시간에 따른 보상은 $R_{t+1, time}$, GU 전력량의 평균이 조건에 부합함에 따른 보상은 $R_{t+1, complete}$, 이미 UAV가 지나온 point를 한 번 더 방문함에 따른 패널티는 $R_{t+1, visited}$, GU들이 충전 받은 양과 UAV가 사용한 전력의 비율에 따른 보상은 $R_{t+1, efficiency}$ 이다. 각 보상은 식 (8)~(11)과 같이 정의하며, 각 agent가 얻은 보상을 묶어 식 (12)과 같이 보상 벡터로 정의한다. 이는 UAV가 최적의 경로를 탐색시 고려해야 하는 값을 포함하여 학습에 사용될 상태 정보에 사용한다.

$$\begin{aligned} R_{t+1, time} &= -(t_{move} + t_{hovering}) \\ &= -\left(\frac{d_{total}}{v_{UAV}} + \sum_i t_{hovering, i}\right) \end{aligned} \quad (8)$$

(v_{UAV} : 2.5m/s, d_{total} : 총 이동거리)

$$R_{t+1, complete} = \begin{cases} 0 & not\ complete \\ +200 & complete \end{cases} \quad (9)$$

$$R_{t+1, visited} = \begin{cases} -500 & already\ visited \\ 0 & not\ to\ visit \end{cases} \quad (10)$$

$$R_{t+1, efficiency} = \frac{\Sigma P_{GU}}{\Sigma P_{used}} \quad (\beta=30: \text{가중치}) \quad (11)$$

$$R_{t+1} = [R_{t+1, time}, R_{t+1, complete}, R_{t+1, visited}, \beta R_{t+1, efficiency}] \quad (12)$$

큐-러닝은 정책 π 에 따라 환경 상태에서 에이전트가

결정한 행동에 따른 누적 보상에 해당하는 행동-가치 함수 $Q_{\pi}(s, a)$ 를 학습하게 된다. 큐-함수를 적절하게 업데이트하여 학습을 수행한다. 큐-함수는 다음과 같은 수식과 매개변수를 통해 업데이트 된다^[10].

$$Q(S_t, a_t, i) \leftarrow Q(S_t, a_t, i) + \alpha [R_{t+1} + \gamma \max_a Q(S_{t+1}, a, i) - Q(S_t, A_t, i)] \quad (13)$$

표 2. 강화학습 환경 변수

Table 2. Reinforcement Learning Parameters.

Parameters	Value
α	0.2
γ	0.95
ϵ	0.5
ϵ_{∇}	0.997
$\epsilon_{\min}$	0.01

여기서 α 는 학습율(learning rate)을 γ 는 할인율(discount factor)을 의미한다. 또한, 행동을 결정하기 위한 정책으로 ϵ decay 정책을 사용하였고 ϵ 은 초기 ϵ , ϵ_{∇} 는 decay factor, $\epsilon_{\min}$ 는 최소 ϵ 값을 의미한다. 또한, 보상에 따른 행동 선택에 있어서 샘플간의 상관성(correlation)을 낮추고 학습의 안정성을 높이기 위해 Replay Memory 기법을 사용한다.

시뮬레이션 기반 성능 검증을 위해 UAV 1개, GU 10개로 구성된 네트워크를 고려하였으며 5,000번의 에피소드에 대해 시뮬레이션이 수행되었다. 본 연구에선 Python을 이용하여 상술한 환경, 에이전트, 상태, 행동, 보상과 표 2의 환경변수에 따라 계산되는 큐-함수를 이용해 강화학습을 설계하였다.




그림 3. 누적 보상 결과 그래프(x/y축: 에피소드/보상)
Fig. 3. Reward History Graph(x/y axis: episode/reward).

그림 3의 경우 누적 보상 결과를 보여주고 있다. 큐-러닝 강화학습 에이전트는 에피소드를 거듭하면서 더 높은 보상을 주는 행동을 선택하기 위해 학습된다. 이

는 그림 3의 그래프 양상에서도 나타나고 있다. 에이전트가 3,000번의 에피소드를 거듭하면서 최고 보상을 경험하고 2,000번의 추가 경험을 하여도 가장 높은 보상을 주는 행동을 선택하고 있는 것을 그래프의 수렴을 통해 보여주고 있다.




그림 4. 학습된 UAV의 비행경로

Fig. 4. Optimized UAV's path.

표 3. 최적화된 비행경로 측정 시간

Table 3. Optimized Path Measured Flight Time.

t_{hov} [sec.]	t_{move} [sec.]	t_{total} [sec.]
67.35	38.75	106.09

그림 4에선 학습된 UAV의 비행경로를 보여주고 있다. 강화학습을 통해 계산된 CP-n으로 라벨링된 호버링 지점과 파란색 점선의 비행경로를 확인할 수 있다. 또한, 노란색 점선으로 구분된 충전 빔의 영역과 더불어 GU가 충전 빔 안에 들어가 있는 것을 확인할 수 있다. 무작위로 배치된 10개의 GU들의 초기 전력량을 30~100 mW까지 무작위로 결정해주었으며, 본 논문에서는 브루트 포스의 결과값과 비교를 위해 seed 값을 고정하여 진행하였다. 큐-러닝 에이전트의 학습 결과, GU들의 목표 충전 전력량인 300 mW까지 충전해 주기 위한 호버링 시간은 67.35초, 계산된 비행경로를 따라 비행하기 위한 시간은 38.75초, 총 106.09초 소요되었다.

강화학습 설계의 유효성을 검증하기 위해 호버링 지점을 K-means Clustering을 이용하여 GU들을 군집화해 계산된 중앙값을 기준으로 trial-and-error 방식으로 가능한 여러 지점을 정하고, 비행경로는 브루트 포스 기법을 이용해 모든 경우의 수를 계산하였다. 그 결과, 강화학습을 통해 최적화된 비행경로 측정 시간인 표 3과 같은 결과를 보인 것을 확인할 수 있었다.

IV. 결 론

본 논문에서는 차세대 무선전력전송 UAV에 활용될 수 있는 큐-러닝 강화학습 설계방법을 공개하였다. IoT 네트워크의 활성화를 위한 방법으로 무선전력전송 UAV가 제안되었고, UAV의 비행경로 등을 최적화하기 위한 연구들이 수행되고 있다. 그 중 최적화가 필요한 부분 중 하나는 호버링 지점의 최적화이다. 전력 공급량은 호버링 지점과 GU의 거리와 반비례하는 관계를 갖고 있으므로 전력효율화를 위해 호버링 지점의 최적화는 필수이다. 본 논문에서는 배터리 잔량을 기반으로 호버링 지점을 최적화하고, 계산된 호버링 지점을 기반으로 비행경로를 계산하는 큐-러닝 강화학습의 설계 방법을 제안한다. IoT 네트워크 시뮬레이션 환경에서 누적보상 결과 그래프를 통해 에이전트가 학습하고 있음을 확인할 수 있었고, 그 측정 결과 역시 가능한 모든 경우의 수를 경험하는 trial-and-error 및 브루트 포스 기법과 비교했을 때 같은 결과를 달성함을 확인하였다.

REFERENCES

- [1] S. Gupta, "An overview of Internet of Things (IoT): Architectural aspects, challenges, and protocols," *Concurrency and Computation: Practice and Experiment*, vol. 32, no. 21, 2018.
- [2] T. Sanislav, G. D. Mois, S. Zeadally, and S. C. Folea, "Energy Harvesting Techniques for Internet of Things (IoT)," *IEEE Access*, vol. 9, pp. 39530-39549, Mar. 2021.
- [3] S. Chen, D. Liu, and Y. Zhao, "Target Localization and Power Allocation Using Wireless Energy Harvesting Sensors," *Electronics*, vol. 10, no. 21, p. 2592, Oct. 2021.
- [4] G. Bedi, G. K. Venayagamoorthy, R. Singh, R. R. Brooks, and K.-C. Wang, "Review of Internet of Things (IoT) in Electric Power and Energy Systems," *IEEE Internet of Things Journal*, vol. 5, no. 2, pp. 847-878, Apr. 2018.
- [5] J. Xu, Y. Zeng, and R. Zhang, "UAV-Enabled Multiuser Wireless Power Transfer: Trajectory Design and Energy Optimization," in *Proc. Asia-Pacific Conf. Communications (APCC)*, Perth, WA, Australia, pp. 764-769, 2017.
- [6] J. Xu, Y. Zeng, and R. Zhang, "UAV-Enabled Wireless Power Transfer: Trajectory Design

- and Energy Optimization,” IEEE Transactions on Wireless Communications, vol. 17, no. 8, pp. 5092–5106, Aug. 2018.
- [7] Y. Hu, X. Yuan, J. Xu, and A. Schmeink, “Optimal 1D Trajectory Design for UAV-Enabled Multiuser Wireless Power Transfer,” IEEE Transactions on Communications, vol. 67, no. 8, pp. 5674–5688, Aug. 2019.
- [8] L. R. Varshney, “Transporting Information and Energy Simultaneously,” in Proc. IEEE International Symposium on Information Theory (ISIT), Toronto, Canada, pp. 1612–1616, July 2008.
- [9] T. T. Oladimeji, P. Kumar, and M. Elmezughi, “An improved path loss model for 5G wireless networks in an enclosed hallway,” Wireless Networks, vol. 30, pp. 2353–2364, Feb. 2024.
- [10] C.J.C.H. Watkins, Learning from Delayed Rewards, Ph.D. thesis, King’s College, London, May 1989.

— 저 자 소 개 —



김 대 술(학생회원)
2024년 중앙대학교
전자전기공학부 학사과정

<주관심분야: 신호처리, 이동통신, 인공지능, 회로설계>



손 민 정(비회원)
2024년 중앙대학교
전자전기공학부 학사과정

<주관심분야: 이동통신, IoT 네트워크, 인공지능, 신호처리>



하 서 영(비회원)
2024년 중앙대학교
전자전기공학부 학사과정

<주관심분야: 의료영상처리, 딥러닝, 컴퓨터>



Muy Sengly(비회원)
2018년 Institute of
Technology of
Cambodia, Dept. of
Electronic and
Electrical Engineering
학사졸업.

2024년 중앙대학교 지능형에너지산업융합학과 석박사과정

<주관심분야: performance optimization by using artificial intelligence, machine learning for wireless networks>



이 정 루(비회원)
1995년 서울대학교
수리과학부 학사 졸업
1997년 서울대학교
수리과학부 석사 졸업.
2006년 한국과학기술원 전기 및
전자공학부 박사 졸업

1997년~2006년 LG전자 Senior Engineer
2006년~2007년 인천대학교 전자공학부 교수
2008년~현재 중앙대학교 전자전기공학부 교수
<주관심분야: Energy-efficient mobile computing, Wireless network protocol (WCDMA, LTE, LTE-A, Mobile WiMAX), Resource management in wireless network, Energy-efficient wireless communication protocols>