



캡스톤디자인

결과 보고서

강통 조

김도원, 윤희준, 이선우, 이지환, 황건하





CONTENTS

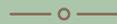
과 제 의 목 적



과 제 내 용 및 과 정



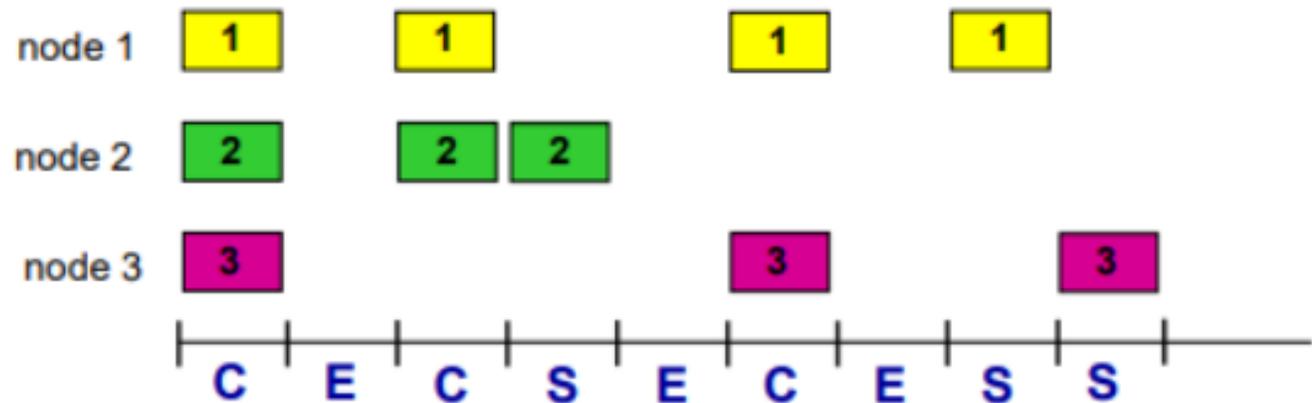
결 론 및 기 대 효 과



01 과제의 목적

• 기존 노드의 프레임 선점 방식(Slotted Aloha)

- 기존 노드의 선점방식은 개수와 용량이 제한된 프레임 안에서 각 노드들이 선점하여 데이터를 전송하는 방식입니다.
- 이 방식은 노드 간의 충돌이 발생할 경우 일정한 지연시간을 가진 뒤 재전송하는 방식을 가집니다.



01 과제의 목적

• 새로운 문제의 해결방법

- 이러한 노드 간 충돌 후 재전송 방식은 불가피하다고 여겨집니다.
- 충돌을 최소화하기 위해 비용을 장비에 투자하기에는 너무도 큰 비용이 발생하기 때문에 한계가 있습니다.
- 우리 과제의 목적은 문제 해결을 소프트웨어적인 관점으로 보아 각 노드 간의 선점 시 발생하는 충돌을 자가 학습을 통해 최소화 할 수 있는 강화학습을 도입하고자 합니다.

02 과제 내용 및 과정

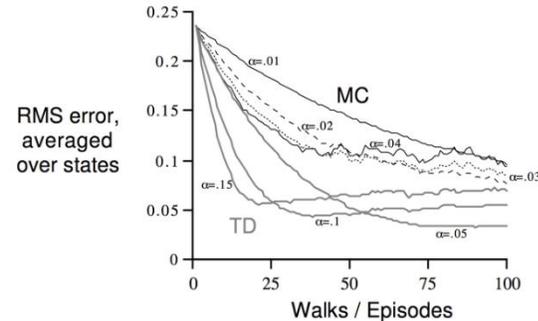
• 강화학습 알고리즘 적용의 적시성 검토

- 알고리즘을 적용하기에 앞서 노드 통신의 어떤 부분에 알고리즘을 적용하는 것이 좋을지 검토가 필요합니다.
- 어떤 알고리즘을 적용하는 것이 성능을 향상시키는지 검토가 필요합니다.
- 결론적으로 강화학습 알고리즘들의 특성을 파악 후 노드 경쟁 방식에 적용하여 상황별 성능을 비교 분석하기로 했습니다.

02 과제 내용 및 과정

• 강화학습 알고리즘 종류와 적용

- MC has high variance, zero bias
 - Good convergence properties
 - (even with function approximation)
 - Not very sensitive to initial value
 - Very simple to understand and use
- TD has low variance, some bias
 - Usually more efficient than MC
 - TD(0) converges to $v_{\pi}(s)$
 - (but not always with function approximation)
 - More sensitive to initial value



❖ MC는 variance가 높은 대신 bias가 없고, TD는 variance가 낮은 대신 bias가 있다.

- 위에서 설명한 Monte Carlo(MC)와 Temporal Difference(TD)의 성능 차이를 비교하기 위해 같은 환경을 만들어 줍니다.
- 두 알고리즘의 차이로는 모든 노드들이 전송을 성공하는 것을 관점으로 보는 것(MC)과 노드들이 전송을 시도하는 각 step(TD)을 관점으로 보는 것에 대한 차이입니다.
- 여기서 우리는 두 알고리즘이 노드, 슬롯의 개수, 프레임의 전송 용량에 따라 성능이 좋은 알고리즘이 다르다는 것을 알 수 있었습니다.

02 과제 내용 및 과정

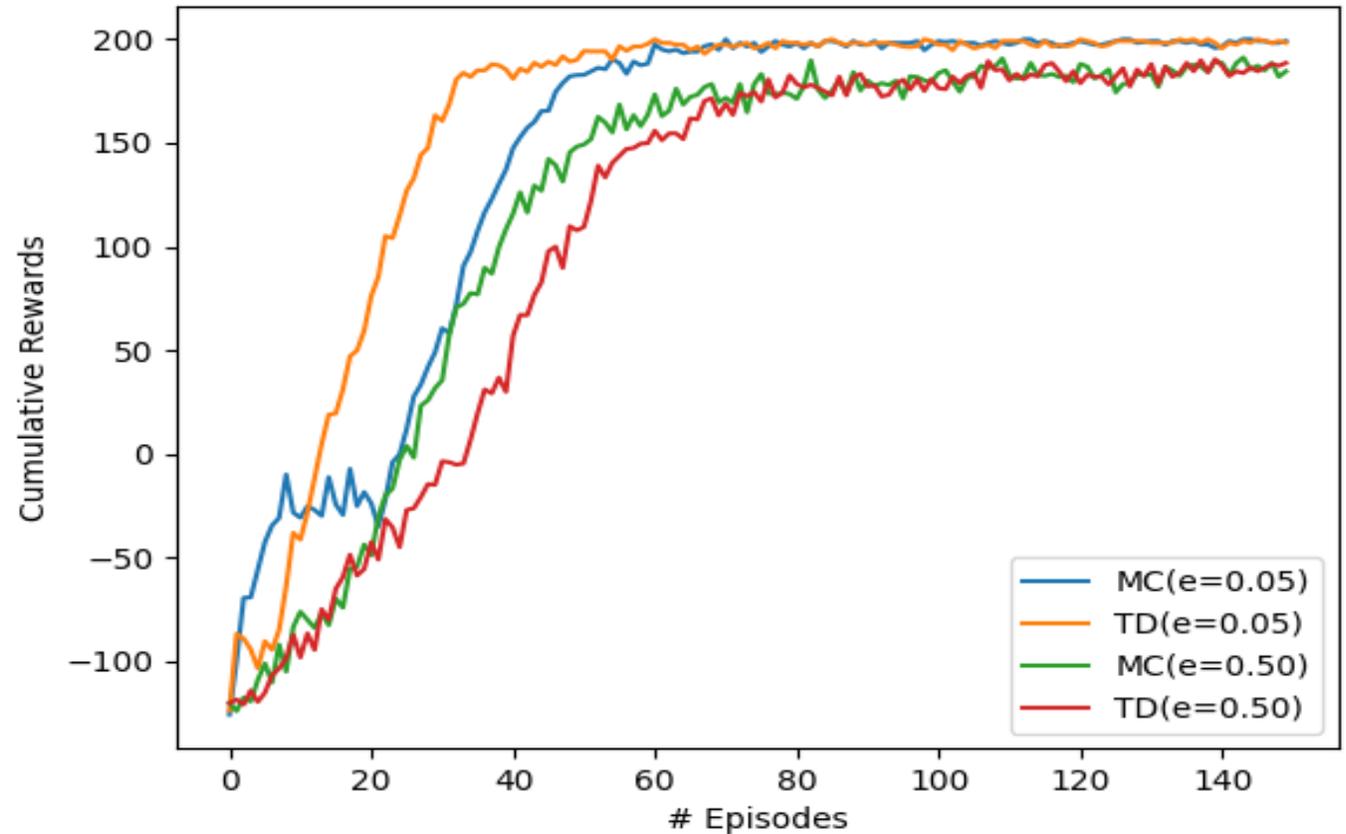
• 강화학습 알고리즘 연구과정과 결과

- 알고리즘의 성능 향상을 Factor별로 비교하기 위해 두 가지 경우로 나누어 실험을 진행하였습니다.
- 첫 번째 실험에서는 epsilon-greedy 알고리즘 적용 부분에 사용하는 epsilon을 다르게 하였습니다.
- 두 번째 실험에서는 MC와 TD알고리즘에 Episode가 종료되고 받는 Reward인 R_2 의 크기를 다르게 하였습니다.

03 결론 & 기대효과

• Figure 1

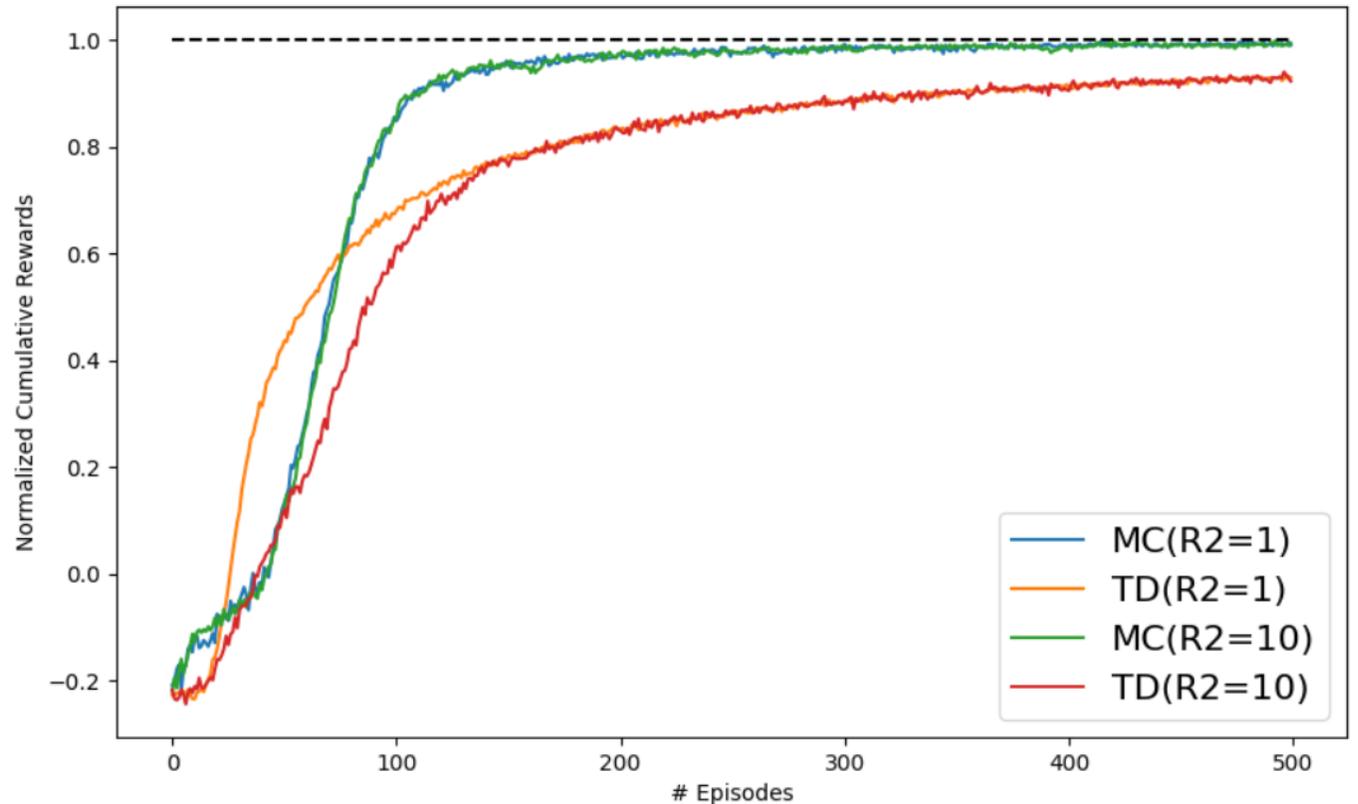
- 실험 1의 결과입니다. 그래프의 Legend에 보이는 ϵ 의 값이 작을수록 알고리즘의 다음 Action 선택이 현재 Q-Table의 최대 값에 대해 Greedy해지는 성질이 있습니다.
- 두 알고리즘에 주어지는 Reward의 크기는 같습니다.
- 그래프의 결과에서 보이듯 ϵ 의 값이 작을수록 MC가 TD에 비해 더 빨리 수렴하는 것을 알 수 있습니다.
- 하지만 ϵ 의 값이 커질 경우 두 알고리즘 모두 성능이 떨어지는데, 알고리즘간의 상대적인 성능은 ϵ 의 값이 작을 경우와는 반대인 양상을 볼 수 있습니다.



03 결론 & 기대효과

• Figure 2

- 실험2의 결과입니다. 각 Node가 선택을 하였을 때 주는 Reward의 값을 R_1 , Episode가 끝났을 때 주는 Reward 값을 R_2 로 나누어 $R_1=R_2$ 일 때와 $R_1<R_2$ 일 때로 나누어 실험을 진행했습니다.
- 그래프는 500개의 random seed를 수행한 후, 받은 전체 reward를 평균 값으로 표준화 하여 나타내었습니다.
- MC의 경우에는 R_2 의 크기가 달라져도 큰 영향을 받지 않고 비슷한 그래프를 그리는 경향을 보였습니다.
- TD의 경우에는 $R_1<R_2$ 인 경우가 수렴속도, 변동 폭의 안정성 부분 모두 떨어지는 경향을 보였습니다.



• 강화학습 알고리즘을 활용한 노드 선점방식 개선

- 본 연구에서는 간단한 알고리즘(MC와 TD)을 이용하여 결과를 도출 해보았습니다. 이 연구를 통하여 알고리즘 별로 놓인 Factor와 환경에 따라 다른 성능 향상이 보인다는 것을 확인하였습니다.
- e값이 작을수록 greedy한 선택을 보다 많이 하게 되므로, 목표치에 빠르게 수렴하는 경향성을 확인하였습니다.
- Reward(R1, R2)의 차이에 따라서는 MC와 TD에 제한적인 영향을 미치며, 경우에 따라서는 성능에 변동성을 줄 수 있습니다.
- 불가피한 노드 간의 충돌을 알고리즘을 통하여 최대한 줄여 나갈 수 있도록 하고자 합니다.
- 물리적인 작업을 통한 통신 시스템 증축보단 소프트웨어적으로 보다 간결한 작업 수행이 될 것이라 미루어 짐작하고 있습니다.
- MC와 TD 이외의 다양한 알고리즘을 연구하고 직접적인 경험을 통하여 통신 노드 간의 선점방식에 강화학습을 적용할 때에 더 복잡하지만 상황에 맞는 알고리즘을 적용한다면 더 좋은 결과를 얻을 수 있다는 것을 알 수 있었습니다.

• 논문 침삭

밀집된 통신기기의 무선접속 알고리즘에
적용할 수 있는 강화학습 알고리즘에 대한 비교 연구
이선우, 김도원, 윤희준, 이지환, 황건하, 신경섭,
상명대학교.

fish9898@naver.com, uksu4178@gmail.com, yunhi108@gmail.com, 8890@gmail.com, jeehanoo@naver.com, kerrhin@trnmu.ac.kr

A Study on the Reinforcement Algorithm based Medium Access Algorithm in a Densely Deployed Wireless Networks

Lee Seon Woo, Kim Do Won, Yoon Hee Jun, Lee Ji Hwan, &
Hwang Geon Ha, and Shin Kyung Seop,
Sangmyung University.

요약

본 논문은 기존 강화학습을 활용한 통신 프로토콜 연구에서 주로 다루어진 Q-learning 기반 알고리즘보다 더 기본적인 강화학습 알고리즘인 Temporal-Difference(TD)와 Monte-Carlo(MC)를 통신 알고리즘에 적용하여 강화학습 방식에 따른 네트워크 접속성능의 비교분석을 진행하였다. 실험을 위해 알고리즘은 대용량의 데이터들 작은 단위로 나누어 전송하는 다중 사용자 환경을 가정하였다. 본 논문에서는 TD와 MC 알고리즘에 동일한 reward를 주기만 ϵ -greedy 방식을 사용하는 경우에 ϵ 값을 다르게 설정하여 성능을 비교하는 실험과 ϵ 값을 고정하고 reward를 다르게 하는 실험을 수행하였다. 실험 결과 TD와 MC를 활용한 노드 간 통신에 ϵ 값이 작을수록 모두 성능이 향상되는 경향성을 확인하고, 최종 reward의 차이에 따라 TD의 성능이 변화가 더 크다는 것을 확인하였다.

I. 서론

네트워크 환경이 모바일 기기와 IoT 기기의 증가로 **폭발적** 증감함에 따라 효율적인 데이터 전송 프로토콜의 필요성이 커져가고 있다. 이에 부응하여 추가적으로 통신시도를 증감하지 않고도 네트워크의 효율성을 높일 수 있는 강화학습을 활용한 통신 프로토콜 알고리즘이 많이 제안되어왔다. 기존 연구에서는 라우팅 프로토콜에 강화학습의 일종인 Q-learning을 활용하여 노드 경로 선택을 최적화하는 방식으로 네트워크의 효율성을 높이는 연구가 꾸준히 있었다. [1][2].

본 논문에서는 통신 알고리즘에 강화학습을 적용하여 서로 다른 노드가 동시에 데이터를 전송하여 충돌하는 상황을 방지하고자 한다. 기존에 연구가 많이 이루어진 노드는 서로의 상태를 모르고 일방적으로 데이터를 전송하므로 통신을 위한 알고리즘으로 model-free prediction이 적당하다. model-free 알고리즘은 환경에 대한 정보를 알지 못하는 경우에 적용할 수 있고, 여러 도메인에 동일한 방법을 적용할 수 있다는 장점이 있다. prediction을 선택한 policy를 통해 어떤 value function을 갖는 상태이며 최적의 행동을 할지보다 value loss의 수렴 여부가 중요하다. 본 논문에서는 기존 연구에서 주로 다루어진 Q-learning 기반 알고리즘 보다 더 기본적인 강화학습

알고리즘 중 Monte-Carlo(MC)와 Temporal-Difference(TD) 두 가지 방식을 통신노드의 지연된 액세스 프로토콜에 적용하여 성능을 비교함으로써 네트워크의 효율성을 더 높일 수 있는 방안을 비교분석하였다.

II. 본론

MC는 episode를 진행하며 return을 저장해두고 episode가 종료된 이후에 그 결과로 학습한다. return은 discounted reward이며 다음과 같다.

$$G_t = R_{t+1} + \gamma R_{t+2} + \dots + \gamma^{n-1} R_n \quad (1)$$

위의 return에 따라 policy π 에 대한 value function이 업데이트된다.

$$v_t(s) = E_t[G_t | S_t = s] \quad (2)$$

Episode가 진행됨에 따라 다음과 같이 value function이 업데이트된다.

$$V(S_t) \leftarrow V(S_t) + \alpha(G_t - V(S_t)) \quad (3)$$

MC는 실험한 후에 통계를 내는 단순한 형태로 episode가 끝나야만 학습이 가능하다. TD는 MC와 다르게 한 단계씩 학습하는 방식이 가능하다. 이 경우 value function은 다음과 같이 업데이트될 수 있다.

$$V(S_t) \leftarrow V(S_t) + \alpha(R_{t+1} + \gamma V(S_{t+1}) - V(S_t)) \quad (4)$$

MC에서의 value function에서 G_t 는 discounted reward의 합이지만, TD에서는 episode가 완료되어야 하는 G_t 대신에 다음 step의 예측으로 현재 예측을 업데이트하는 $R_{t+1} + \gamma V(S_{t+1})$ 를 사용한 것을 볼 수 있다.

본 논문에서 진행된 실험은 다음과 같은 환경을 가정하여 설계되었다. 10Mbyte의 데이터를 1Mbyte씩 나누어 전송하며 10개의 slot으로 이루어진 stage에 데이터를 다 전송할 경우 한 episode가 끝난 것으로 가정하고 1Mbyte를 전송하는 것을 한 step으로 가정하였다. 크게 MC 알고리즘은 한 episode가 끝났을 때마다, TD 알고리즘은 한 step을 수행할 때마다 policy를 업데이트한다는 차이가 있다.

실험은 총 2가지 방식으로 진행되었으며 이는 다음과 같다. 실험 1은 epsilon(ϵ)-greedy 알고리즘을 활용하여 ϵ 값이 작을수록 예측 value 값이 가장 큰 행동을 선택할 가능성이 크고 ϵ 값이 클수록 무작위적으로 행동을 선택한다는 것을 고려하여 ϵ 값에 따른 randomness가 각 알고리즘의 성능에 미치는 영향을 분석하기 위한 실험이다. 이를 확인하고자 TD/MC 알고리즘에 0.5, 0.05, 0.1의 ϵ 값을 부여 얼마나 성공적으로 데이터를 전송하였는지를 비교하였다. Fig.1 그래프는 실험 1의 결과를 보여준다.

실험 2는 TD/MC 알고리즘에 reward가 미치는 영향을 비교 분석하기 위해 설계되었다. reward를 R1(한 step을 수행하고 받는 reward), R2(또는 step이 끝난 episode 종료 후 받는 reward)로 구분하여 R1=R2인 경우, R1<R2인 경우로 reward 값을 조정하여 실험하였다. Fig.2 그래프는 실험 2의 결과를 보여준다.

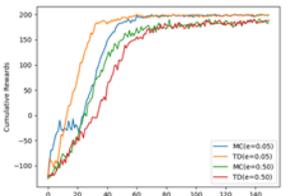


Fig 1. ϵ 값에 따른 알고리즘의 성능 변화.

위의 그래프는 MC와 TD에 각각 고정된 reward 값에 서로 다른 ϵ 값을 부여 나온 결과이다. ϵ 의 값이 클수록 다음 step에 random 한 선택을 할 확률이 높아진다. 위의 그래프에서 볼 수 있듯이, ϵ 의 값이 작을수록 TD가 MC에 비해 더 빨리 수렴하게 되어 유리한 결과를 보여주기만, ϵ 의 값이 적절할 경우 그 반대의 결과가 나오게 된다.

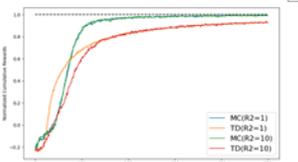


Fig 2. Reward에 따른 알고리즘의 성능 변화.

위의 그래프는 reward 값에 따른 MC와 TD의 결과이다. 기본적으로 R1을 1로 부여하고, R1=R2일 때와 R1<R2일 때를 비교하였다. 그래프는 각 unit이 episode당 받는 전체 reward를 서로 다른 random seed에 대한 평균값으로 표현하여 나타낸 결과이다. 500개의 random seed를 사용한 환경으로, ϵ -greedy 방식으로 action을 선택한다. TD는 step마다 random 한 확률을 가져 exploration적인 선택을 하게 되고, MC는 첫 선택을 해당 step에 고정적으로 가져가게 하여 TD에 비해 더 greedy한 action 선택을 하였다. 위의 그래프에서 볼 수 있듯이, MC의 경우 reward의 차이에 큰 영향을 받지 않아 비슷한 그래프 그리는 경향을 보였고, TD는 R2가 적절에 따라 수렴속도와 변동폭의 안정성이 다소 떨어지는 경향을 보였다.

III. 결론

본 논문에서는 MC와 TD를 사용한 노드 간 통신에 ϵ 값이 작을수록 빠르게 목표지에 수렴하는 경향성을 확인하였다. ϵ 값이 작을 경우, MC와 TD 모두 일회적인 선택이 아닌 greedy한 선택을 더 많이 하게 되므로 ϵ 값이 큰 경우보다 더 빨리 수렴하게 된다. 반면, reward의 크기 변화가 MC에 미치는 영향은 제한적이며 TD의 경우 Bias가 생겨 성능에 변동성이 커지는 부작용이 나타날 수 있다. 결과적으로 두 알고리즘 모두에 결정적인 영향을 미치는 요소는 ϵ 값으로, TD가 더 greedy한 선택을 할수록 MC보다 유리해지는 경향을 보인다는 것을 확인하였다.

ACKNOWLEDGMENT

본 연구는 2021년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. NRP-2021R1P1A1A040099).

참고 문헌

- [1] 김희정, 정진우, "무기적 Q-table 업데이트를 활용한 무선 라우팅 프로토콜", 한국통신학회논문지 45.12 (2020) pp. 2099-2106.
- [2] 김희진, 고호진, "수동 센서 네트워크에서 강화학습 기반 무선 라우팅 프로토콜", 한국통신학회논문지 45.10 (2020) pp. 1718-1719.



THANK YOU

