

# 밀집 무선랜 환경에서의 서비스 품질 보장을 위한 지능형 접속 제어 시스템

정창현<sup>1</sup>, 이상희<sup>2</sup>, 이재욱<sup>3\*</sup>

<sup>1</sup>국립부경대학교 정보통신공학과 학생, <sup>2</sup>국립부경대학교 지능로봇공학과 석사과정, <sup>3</sup>국립부경대학교 정보통신공학과 교수

## AI-Based Association Control System for QoS in Dense Wireless LANs

Chang-Hyun Jung<sup>1</sup>, Sang-Hui Lee<sup>2</sup>, Jae-Wook Lee<sup>3\*</sup>

<sup>1</sup>Student, Department of Information and Communication Engineering, Pukyong National University

<sup>2</sup>Master's Student, Department of Intelligent Robot Engineering, Pukyong National University

<sup>3</sup>Professor, Department of Information and Communication Engineering, Pukyong National University

**요약** 기존의 무선랜 네트워크에서는 각 Access Point (AP)가 독립적으로 사용자 접속 제어를 수행하기 때문에, 많은 사용자들이 특정 AP에 집중적으로 연결되어 전체 사용자들의 서비스 품질(Quality of Service, QoS)이 저하되는 문제가 발생한다. 이러한 문제는 대규모 실내 행사장과 같이 사용자가 밀집된 무선랜 환경에서 더욱 심각하게 나타난다. 본 논문에서는 밀집된 무선랜 환경에서 QoS를 보장하기 위한 심층 강화학습 기반 사용자 접속 제어 시스템을 제안한다. 제안된 시스템은 중앙 컨트롤러가 사용자(Station, STA)의 상태 정보를 수집하고, 심층 강화학습(Deep Reinforcement Learning)을 활용하여 각 사용자에게 최적의 AP를 추천한다. 이를 통해 AP 간 부하를 균형 있게 분산시키며, 사용자의 불필요한 접속 변경 오버헤드를 최소화하면서 QoS를 효과적으로 보장할 수 있다. 또한, 본 시스템은 기존 무선랜 인프라를 변경하지 않고 적용 가능하다는 실용적인 장점을 지닌다. 실험을 통해 그 효과성과 우수성을 입증하였다.

**주제어** : 무선랜, 중앙 집중식 네트워크, 심층 Q-네트워크, 최적 경로 제어, 서비스 품질

**Abstract** In dense WLAN environments, user association concentrated on a single Access Point (AP) can severely degrade the overall Quality of Service (QoS). This issue arises from the conventional architecture in which each AP independently handles user associations without coordination. To address this problem, we propose an intelligent user association control system based on deep reinforcement learning (DRL). The proposed system employs a centralized controller that collects real-time status information from user stations (STAs) and recommends the optimal AP for each user. By learning and predicting the best association strategies, the system effectively balances traffic loads across APs and minimizes unnecessary handovers, thereby enhancing QoS. One of the key advantages of our approach is its compatibility with existing WLAN infrastructure, requiring no hardware modifications. We demonstrated its effectiveness through real-world experiments.

**Key Words** : Wireless LAN, Centralized Network, Deep Q-Network, Optimal Path Control, Quality of Service

## 1. 서론

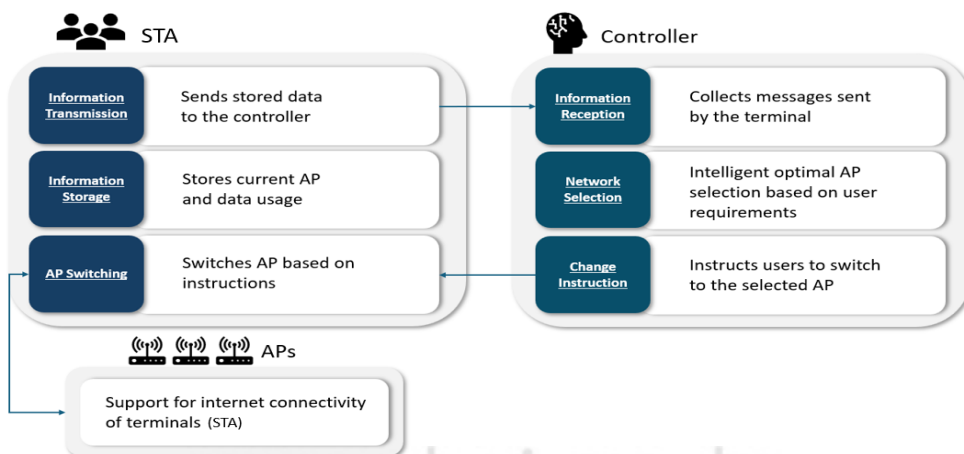
정보화 시대의 도래와 함께 스마트폰, 태블릿, 노트북, Internet of Things (IoT) 단말기 등 무선랜 (WiFi) 사용 기기가 급증하고[1,2], 실시간 스트리밍 서비스 확산으로 데이터 통신량도 꾸준히 증가하고 있다[3]. 이를 수용하기 위해 기존 비면허 대역 외에도 최근 6GHz 대역이 새롭게 무선랜 용도로 할당되었고[4], IEEE 802.11 표준 역시 WiFi 7 (802.11be)로 발전하며 더 넓은 대역폭과 향상된 성능을 제공하고 있다[5,6,7]. 그러나 무선랜은 구조적 한계를 지닌다. WiFi AP 기반 네트워크는 4G/5G 이동통신망과 달리 개별 관리 체계를 따르므로, 커버리지 확장성과 네트워크 관리 효율성에서 제약이 발생한다. 특히 AP가 밀집된 환경에서는 사용자 스테이션 (station (STA)) 이 단순히 신호 세기에 따라 AP에 연결되면, 특정 AP에 사용자가 몰려 트래픽 불균형과 QoS 저하 문제가 발생한다[8]. 또한, 비면허 대역은 누구나 사용할 수 있다는 장점이 있지만, 한정된 대역을 다수가 공유하면서 간섭이 발생하여 통신 QoS가 저하되는 단점이 있다. 이를 해결하기 위해 무선랜에는 간섭 차단 및 주파수 효율 향상 기술이 적용되고 있지만, 간섭 역제의 효율성에 따라 AP가 받는 간섭 영향이 달라지며, 결과적으로 사용자 체감 성능이 달라진다[9]. 더불어, Signal to Noise Ratio (SNR)이 낮은 환경에서는 주파수 효율이 저하되기 때문에 단순한 용량 분석만으로는 성능을 정확하게 평가하기 어렵다[10]. 따라서 단순한 수신 세기나 용량 기반의 AP 선택으로는 사용자가 체감하는 네트워크 품질을 정밀하게 보장하기 어렵다. 최근 사용되는

Mesh WiFi는 다수의 AP를 분산 배치해 커버리지를 확장하지만, 밀집된 환경에서는 AP 간 접속 반경이 겹치지 않도록 설계되므로 특정 AP에 부하가 집중되는 문제가 있다[11]. 또한 제조사 간 호환성 문제와 높은 도입 비용은 소규모 사업자에게 부담이 된다.

본 논문에서는 밀집 WLAN 환경에서 기존 인프라를 변경하지 않고도 QoS를 보장할 수 있는 중앙 집중식 STA 접속 제어 시스템 및 기법을 제안한다. 중앙 제어 서버는 STA의 상태 정보를 수집하고, STA 상태 정보와 각 AP의 부하 및 전송 성능을 고려하여 최적의 AP를 선택한다. 단순 신호 세기 기반이 아닌, 전환 오버헤드 대비 성능 향상이 충분할 때만 AP를 전환함으로써 현실성과 효율성을 동시에 확보하였다[12]. 제안 기법의 환경은 상태 공간이 고차원이고 변수들이 연속적인 특성을 가지므로, 기존 Q-table 방식의 Q-learning 기법으로는 한계가 있다[13]. 따라서 심층 신경망을 활용한 DQN을 도입하고, Experience Replay 및 Target Network를 적용해 학습 안정성과 효율성을 확보하였다[14,15]. 실험 결과, 제안 기법은 일반 환경뿐만 아니라 고밀도 사용자 환경에서도 사용자별 트래픽, 대역폭, 지연 시간을 더 공정하게 분배하며 QoS 향상과 네트워크 자원의 효율적 활용이 가능함을 확인하였다.

## 2. 지능형 중앙 집중식 무선랜 시스템

Fig. 1은 본 연구에서 제안하는 시스템을 나타내며, 네트워크 컨트롤러, AP, STA로 이루어진다. AP는 기존



[Fig. 1] Intelligent Centralized Wireless LAN System

과 동일하게 STA에 인터넷 연결 기능만을 수행하며 별도의 기능 수정은 요구되지 않는다. 이에 따라 기존 인프라의 물리적 변경 없이 시스템을 적용할 수 있다는 장점이 있다. 네트워크 컨트롤러와 STA의 주요 구현체와 역할은 다음과 같다.

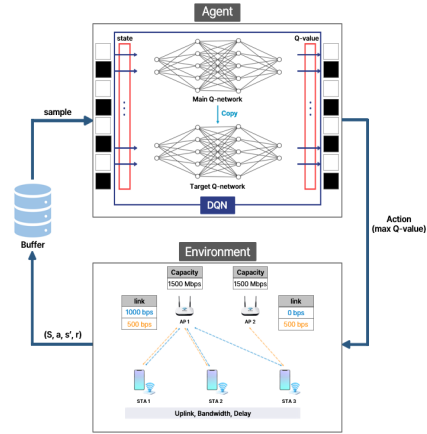
네트워크 컨트롤러는 정보 수신 모듈, 지능형 네트워크 선택 모듈, 변경 지시 모듈로 구성된다. 정보 수신 모듈은 각 STA가 송신한 메시지를 수집하는 기능을 수행한다. 수집된 메시지에는 현재 STA의 통신 상태 및 접속된 AP 등의 정보가 기재될 수 있으며, 구현 목적에 따라 변경할 수 있다. 해당 정보는 지능형 네트워크 선택 모듈에 전달되어 지능형 기법을 적용하여 사용자별 최적의 AP를 선택한다. 본 연구에서는 QoS를 고려하여 AP별로 처리하는 데이터양, 대역폭, 지연 시간을 DQN을 활용하여 균등하게 배분함으로써 최적의 인터넷을 사용할 수 있도록 설계했다. 끝으로, 변경 지시 모듈은 위의 선택된 AP들을 사용자들에게 알리는 기능을 수행한다. 해당 메시지를 받은 STA는 AP 변경 모듈을 통해 AP 접속 경로를 변경한다.

무선랜 변경 후에 STA는 정보 저장 모듈을 통해 자신이 사용한 데이터양, 대역폭, 지연 시간을 측정하고, 정보 송신 모듈을 통해 자신이 측정한 데이터양 및 현재 접속한 AP에 관한 정보 (예, MAC 주소 혹은 SSID 등)를 컨트롤러에 송신한다. 상기에 기술한 일련의 과정을 주기적으로 반복 수행함으로써, 컨트롤러는 지능적으로 STA별 최적의 AP를 선택 및 선택된 AP에 STA를 분배할 수 있다.

### 3. DRL 기반의 사용자 접속 제어 기법

Fig. 2는 본 논문의 시스템 모델을 나타내며,  $M$ 개의 WiFi AP와  $N$ 개의 STA가 존재하고, 각 STA는 네트워크 컨트롤러 (agent)로부터 접속 제어를 받는 중앙 집중식 무선랜 시스템 환경을 가정한다. 에이전트는 STA별로 연결되어야 하는 AP를 선택하고, 해당 정보를 각 STA에게 알린다. STA는 수신받은 AP 선택 정책에 따라 AP를 변경한다. 에이전트는 최적의 AP를 선택하기 DQN 기법을 통해 학습을 수행한다. 학습하는 동안 에이전트는 현재 STA가 연결되어야 할 AP들을 선택하여 STA에게 알리고, STA는 해당 AP로 연결한다. STA는 현재 연결된 AP 정보와 요구하는 데이터 속도, 네트워크 대역폭, 응답 지연 시간 정보를 에이전트에게 알림으로써 에이전트

는 자신이 선택한 결정의 좋고 나쁨을 배우게 되고 지속적으로 상기 과정을 수행하여 최적의 선택을 AI 모델이 배울 수 있도록 한다. 최적의 사용자별 AP 선택 정책을 얻기 위해 DRL 문제(상태 공간(S)과 행위 공간(A) 그리고 보상 값(R))을 다음과 같이 정의하였다.



[Fig. 2] System Architecture

#### 3.1 State

상태 공간 S는 각 STA별 현재 연결된 AP의 상태 공간, STA별 요구하는 데이터 속도, AP가 STA에게 할당해주는 네트워크 대역폭, 응답 지연 시간의 상태 공간으로 아래와 같이 정의된다.

$$S = \prod_{n=1}^N W_n \times \prod_{n=1}^N D_n \times \prod_{n=1}^N B_n \times \prod_{n=1}^N L_n$$

$W_n$ 은 STA  $n$ 이 연결될 수 있는 AP와  $D_n$ 은 STA  $n$ 이 요구하는 데이터 속도의 상태 공간들을 나타낸다. 또한  $B_n$ 과  $L_n$ 은 각각 STA  $n$ 의 네트워크 대역폭과 응답 지연 시간의 상태 공간을 나타낸다. 각 상태공간  $W_n = \{1, 2, \dots, M\}$ 과  $D_n = \{0, \dots, D_{\max}\}$ ,  $B_n = \{0, \dots, B_{\max}\}$ ,  $L_n = \{0, \dots, L_{\max}\}$ 로 정의할 수 있으며,  $D_{\max}$ ,  $B_{\max}$ ,  $L_{\max}$ 은 환경에서 제공할 수 있는 최대 데이터 속도, 최대 대역폭, 최대 지연 시간을 나타낸다.

#### 3.2 Action

행위 공간 A는 각 STA가 연결되어야 할 AP들로 나타내며 다음과 같이 정의한다.

$$A = \prod_{n=1}^N A_n$$

여기서  $A_n$ 는 STA  $n$ 이 연결되어야 하는 AP를 의미하고  $A_n$ 의 상태 공간은  $W_n$ 과 같다.

### 3.3 Reward

보상  $R$ 은 다음과 같은 세 가지 목표를 가진다.

- ① STA의 데이터 전송 요구량이 충족되게 한다.
- ② 공평성을 고려하여 최적의 QoS를 제공한다.
- ③ 전환 시 서비스 끊김과 지연을 최소화한다.

$$r_{1_n}(s, a) = \max \left\{ d_n - \frac{B_{a_n}}{N_{a_n}} (\delta(w_n = a_n)) \right. \\ \left. + p(1 - \delta(w_n = a_n)), 0 \right\} \quad (1)$$

수식 (1)은 특정 상황  $s$ 에서 행위  $a$ 를 선택할 시 STA  $n$ 의 요구 사항 충족도를 나타내며 낮은 값일수록 요구 사항을 더 충족한다는 것을 의미한다.  $d_n$ 은 STA  $n$ 이 요구하는 데이터 속도이고,  $B_{a_n}$ 과  $N_{a_n}$ 은 STA  $n$ 과 연결되는 AP  $a_n$  사이의 데이터 속도와 연결된 STA의 수를 의미한다.

수식 (2), 수식 (3)은 각각 STA  $n$ 의 대역폭 및 지연 시간 요구 사항 충족도를 나타내며 높은 값일수록 요구 사항을 더 충족한다는 것을 의미한다. 수식 (2)에서  $b_n$ 은 STA  $n$ 이 제공 받은 대역폭이고,  $B_{th}$ 는 대역폭 임계값을

의미한다.

$$r_{2_n}(s, a) = \max(0, b_n - B_{th}) \\ \{ \delta(w_n = a_n) + p(1 - \delta(w_n = a_n)) \} \quad (2)$$

$$r_{3_n}(s, a) = \max(0, L_{th} - l_n) \\ \{ \delta(w_n = a_n) + p(1 - \delta(w_n = a_n)) \} \quad (3)$$

수식 (3)에서  $l_n$ 은 STA  $n$ 이 경험하는 지연 시간을 의미하고,  $L_{th}$ 는 지연 시간 임계값을 의미한다. 또한,  $\delta$  함수는 조건이 참이면 1을 출력하고 그렇지 않으면 0을 출력하는 함수로, 기존의 AP가 변경되지 않으면, 1을 출력하고 AP가 변경된다면 0을 출력한다.  $p$ 는 전체 서비스 시간 동안 STA  $n$ 의 AP 변경으로 인한 연결 시간을 제외한 서비스 받는 시간의 비율을 의미한다.

수식 (4)는 STA들의 공평한 충족도 보장과 개별 보상의 스케일 차이를 보정하고자 Jain's fairness index를 활용하여  $r_i(s, a)$ 를 정의하였다.  $\theta_m()$  함수는 AP  $m$ 에 연결된 STA들의  $r_{i_n}(s, a)$  값을 합하는 함수다. 정의된 보상 값을 통해 동일한 AP에 다수의 STA가 연결되거나 AP가 변경될수록 STA들은 적은 데이터 속도로 서비스받는다.

$$r_i(s, a) = \frac{\left[ \sum_{m=1}^M \theta_m(r_{i_n}(s, a)) \right]^2}{M \sum_{m=1}^M [\theta_m(r_{i_n}(s, a))]^2}, i = (1, 2, 3) \quad (4)$$

<Table 1> DQN Training Algorithm

DQN Training Algorithm for QoS-Aware Path Optimization

- 1: Initialize policy network  $Q(\cdot)$ , target network  $Q_{target}(\cdot)$ , and replay buffer  $D$ .
- 2: Set all hyperparameters;
- 3: Initialize environment with APs and users;
- 4: Generate state space based on possible AP-user assignments;
- 5: for each episode  $E = 1, 2, \dots$  do
- 6:   Reset environment and get initial state  $S$ ;
- 7:   for each step  $t = 1, 2, \dots$  do
- 8:     Select action  $A(t)$  using decayed epsilon-greedy policy;
- 9:     Execute action  $A(t)$  and observe next state  $S(t+1)$ , reward tuple  $R(t)$ , and done flag;
- 10:     Compute reward considering fairness, QoS bandwidth, and latency;
- 11:     Store transition pair  $(S(t), A(t), R(t), S(t+1))$  in replay buffer  $D$ ;
- 12:     if buffer contains at least batch\_size samples then:
- 13:       Select  $B$  batch samples from  $D$ ;
- 14:       Update Q-function;
- 15:        $Q(S(t), A(t)) \leftarrow (1 - \alpha)Q(S(t), A(t)) + \alpha(R(t) + \beta \max_A Q(S(t+1), A))$ ;
- 16:       Update target network:
- 17:        $Q_{target} \leftarrow \tau Q + (1 - \tau)Q_{target}$
- 18:       if done then
- 19:         Store episode metrics;
- 20:         break
- 21:     end for
- 22: end for

수식 (5)는 최종적으로 세 개의  $r_i(s, a)$ 를 목적에 따라 활용할 수 있도록 각 항목에 가중치  $\alpha_i$ 를 두어 최종 보상  $R(s, a)$ 을 정의했다.

$$R(s, a) = \alpha_1 r_1(s, a) + \alpha_2 r_2(s, a) + \alpha_3 r_3(s, a) \quad (5)$$

에이전트는 정의된 상태, 행위 공간들과 보상 값을 토대로 최적의 보상 값을 보장하는 AP 선택 정책을 학습하기 위해  $\epsilon$ -greedy, Experience Replay, Target Network 등의 DQN 기법을 적용한다. Table 1은 제안된 최적의 무선랜 접속 경로 제어 알고리즘의 학습 과정을 보여준다. 학습 단계와 검증 단계는 일반적 상황인 STA가 6개, AP가 3개인 환경과, 밀집된 상황인 STA가 12개, AP가 3개인 환경에 대해 진행했다.

<Table 2> Training Hyperparameter

Parameter	Value	Parameter	Value
STA	6, 12	AP	3
Epsilon Start	0.9	Epsilon Decay	1000
Epsilon End	0.1	TAU	0.1
GAMMA	0.1	Batch Size	128
Replay Buffer	10000	Learning Rate	0.0001
Episode	5000	Time step	20

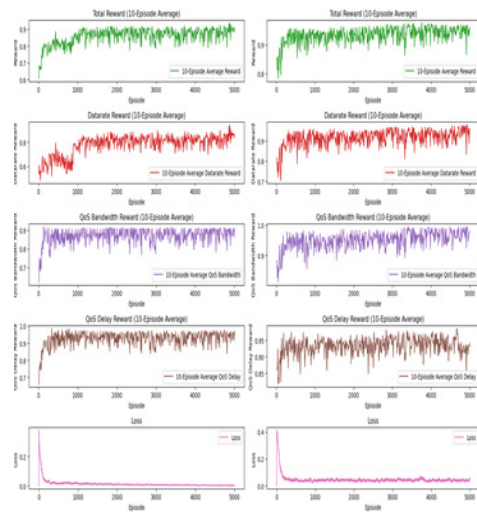
<Table 3> Neural Network Structure

DNN			
Layer		Node	Rate
Input	FC Layer	6, 12	-
	FC Layer	128	-
Hidden	Dropout	-	0.2
	FC Layer	256	-
	Dropout	-	0.2
	FC Layer	729, 531,441	-
Optimizer		Adam	
Activation Function		Relu	

또한,  $B_{th}$ 은 IEEE 802.11ax 표준과 실제 환경을 고려해 1,500Mbps로 설정했으며,  $B_{th}$ ,  $L_{th}$ 은 실제 환경을 고려해 각각 30Mbps, 50ms로 설정했다. 학습에 이용된 파라미터와 신경망 모델은 Table 2, 3에 요약되어 있다.

## 4. 성능 평가

본 논문은 STA의 데이터 전송 요구를 만족하면서 최적의 QoS를 제공하고, AP 전환으로 인한 지연과 서비스 중단을 최소화하는 DQN 기반 무선랜 접속 제어 기법을 제안한다. 성능 평가는 다음 세 가지 관점에서 수행되었다. 첫째, 학습 수렴 여부를 판단하기 위해 에피소드별 평균 보상을 측정하였다. 총보상과 함께 데이터 전송량 보상, 대역폭 보상, 지연 시간 보상을 별도로 분석함으로써, 각 QoS 요소가 어떻게 최적화되는지를 확인하였다. 둘째, 학습 안정성을 평가하기 위해 Smooth L1 Loss를 사용하여 Q-네트워크의 수렴 양상을 분석하였다. 셋째, 제안 기법의 효과를 검증하기 위해 무작위 AP 선택(Random), 고정 분배 방식(Static)과의 비교 실험을 수행하였다.




[Fig. 3] Performance Evaluation

- (a) General Environment (STA = 6) and
- (b) Dense Environment (STA = 12)

Fig. 3 (a)는 AP 3개, STA 6개 환경에서 학습 과정을 보여준다. 총보상은 에피소드 약 1000 이후 안정적인 값을 유지하여 정책 수렴을 확인할 수 있다. 데이터 전송량, 대역폭, 지연 시간 보상 모두 초기 변동 이후 점진적으로 향상되어 안정화되었으며, 이는 STA의 QoS 요구를 충족하는 AP 선택 정책을 성공적으로 학습했음을 증명한다. 손실 함수는 학습 초반 급격히 감소한 뒤 일정 수준에서 유지되어 모델이 효율적으로 수렴하고 있음을 확인할 수 있다.

Fig. 3 (b)는 STA 수를 2배로 증가시킨 밀집 환경에서의 결과를 보여준다. 초기에는 보상 변동이 크지만, 학습이 진행됨에 따라 보상은 안정적으로 수렴하였다. 이는 다양한 네트워크 밀도 환경에서도 효과적으로 작동함을 의미한다. Fig. 4는 제안 기법과 기존 방식 간의 성능 비교 결과이다. 제안 기법은 평균 보상 0.9532로, Random (0.533), Static(0.5245) 대비 우수한 성능을 보였다. 이는 제안된 기법이 네트워크 상태와 STA의 QoS 요구를 반영하여, 효율적으로 자원을 할당하고 최적의 AP 선택을 수행했기 때문이다. 반면, 기존 방식은 네트워크 상태를 고려하지 못해 성능이 낮게 측정되었다. 따라서, 제안 기법은 다양한 환경에서 QoS를 고려한 지능적인 AP 선택을 통해 네트워크 성능을 효과적으로 향상시킬 수 있음을 입증하였다.



[Fig. 4] Performance Comparison by Scenario

## 5. 결론

본 논문에서는 네트워크 성능을 향상하기 위한 중앙 집중식 DQN 기반 무선랜 네트워크의 최적 접속 제어 기법을 제안하였다. 제안하는 시스템은 컨트롤러와 STA 간의 통신을 통해 지능형 분배 알고리즘을 활용하여, STA가 최적의 AP에 연결될 수 있도록 설계되었다. 이를 통해, Mesh WiFi의 단점을 보완하면서도 기존 상용 AP의 수정 없이 구현할 수 있어 경제적 비용을 절감할 수 있는 장점이 있다. 또한, 강화학습 기반의 무선랜 AP 선택 기법을 도입하여 최적의 AP-STA 연결 정책을 학습하고, DQN 알고리즘을 적용하여 성능을 검증하였다. 모의 실험 결과, 제안하는 기법이 다수의 AP가 존재하는 무선 네트워크 환경에서 사용자들의 데이터 속도를 공평하게 배분하고 최적의 AP를 선택할 수 있음을 확인하였다. 본 연구를 통해, 중앙 집중식 시스템을 활용한 무선 자원의

효율적 사용이 가능함을 입증하였으며, 향후 연구에서는 실시간 네트워크 환경과 사용자 이동성을 고려한 강화학습 모델의 확장을 진행할 예정이다. 또한, 사용자 패턴 분석 및 예측을 기반으로 한 무선 네트워크의 최적화 방안을 추가로 연구하여 더욱 지능적 네트워크 운영 기법을 개발하는 것을 목표로 한다.

## REFERENCES

- [1] C.Choi., "A Study On IoT Data Consistency in IoT Environment," *J. Korea Internet Things Soc.*, Vol.8, No.5, pp.127-132, 2022.
- [2] Y.Kyung, T.Kim, and Y.Kim, "Retained Message Delivery Scheme utilizing Reinforcement Learning in MQTT-based IoT Networks," *J. Korea Internet Things Soc.*, Vol.10, No.2, pp.131-135, 2024.
- [3] C. Deng, *et al.*, "IEEE 802.11be Wi-Fi 7: New challenges and opportunities," *IEEE Commun. Surv. Tuts.*, Vol.22, No.4, pp.2136-2166, 4th Quart., 2020.
- [4] FCC, "Unlicensed use of the 6 GHz band; expanding flexible use in mid-band spectrum between 3.7 and 24 GHz," *FCC ET Docket*, No.18-295, Apr. 2020.
- [5] A. Garcia-Rodriguez, *et al.*, "IEEE 802.11be: Wi-Fi 7 strikes back," *IEEE Commun. Mag.*, Vol.59, No.4, pp.102-108, Apr. 2021.
- [6] E. Khorov, I. Levitsky, and I. F. Akyildiz, "Current status and directions of IEEE 802.11be, the future Wi-Fi 7," *IEEE Access*, Vol.8, pp. 88664-88688, 2020.
- [7] N. Korolev, I. Levitsky, and E. Khorov, "Analytical model of multi-link operation in saturated heterogeneous Wi-Fi 7 networks," *IEEE Wireless Commun. Lett.*, Vol.11, No.12, pp.2546-2549, Dec. 2022.
- [8] F. Xu *et al.*, "Designing a practical access point association protocol," in *Proc. IEEE INFOCOM*, San Diego, CA, USA, Mar. 2010.
- [9] D.-J. Deng *et al.*, "IEEE 802.11ax: Highly efficient WLANs for intelligent information infrastructure," *IEEE Commun. Mag.*, Vol.55, No.12, pp.52-59, Dec. 2017.
- [10] S. Verdu, "Spectral efficiency in the wideband regime," *IEEE Trans. Information Theory.*, Vol.48, No.6, pp.1319-1343, Jun. 2002.
- [11] M. Eslami, O. Karimi, and T. Khodadadi, "A survey on wireless mesh networks: architecture, specifications and challenges," in *Proc. IEEE 5th Control Syst. Grad. Res. Colloq.*, Shah Alam, Malaysia, 2014, pp.219-222.
- [12] IEEE Std Assoc., *IEEE Draft Standard for Wireless LAN: High Efficiency WLAN*, IEEE P802.11ax/D6.0, pp. 1-780, Dec. 2019.
- [13] V. Mnih *et al.*, "Playing Atari with deep reinforcement learning," *arXiv Prepr.*, arXiv:1312.5602, 2013.

- [14] V. Mnih *et al.*, "Human-level control through deep reinforcement learning," *Nature*, Vol.518, No.7540, pp.529-533, 2015.
- [15] D. Silver *et al.*, "Mastering the game of Go with deep neural networks and tree search," *Nature*, Vol.529, No.7587, pp.484-489, 2016.

정 창 현(Chang-Hyun Jung) [준회원]




- 2024년 7월 ~ 2024년 8월 : 한국전자통신 연구원 연구연수생
- 2025년 2월 : 국립부경대학교 정보통신공학과(공학사)

<관심분야>

AI 기반 최적화, AI for Network

이 상 희(Sang-Hui Lee) [준회원]



- 2024년 8월 : 국립부경대학교 정보통신공학과(공학사)
- 2024년 9월 ~ 현재 : 국립부경대학교 지능로봇공학과 석사과정

<관심분야>

AI for Network, O-RAN

이 재 욱(Jae-Wook Lee) [정회원]



- 2021년 8월 : 고려대학교 전기 전자 공학과(공학박사)
- 2021년 9월 ~ 2023년 2월 : 한국전자통신 연구원 선임연구원
- 2023년 3월 ~ 현재 : 국립부경대학교 정보통신공학과 조교수

<관심분야>

6G 모바일 네트워크, Network for AI