

# QA-FedDQN: 독립 배치 다중 AP Wi-Fi 네트워크를 위한 품질 인식 적응적 연합 심층 Q-Network

김지하, 박현희\*

명지대학교

{ yaki5896, hhpark\*}@mju.ac.kr

## QA-FedDQN: Quality-Aware Adaptive Federative Deep Q-Network for Distributed Multi-AP Wi-Fi Networks

Jiha Kim, Hyunhee Park \*

Myongji Univ.

### 요약

본 논문은 차세대 IEEE 802.11bn (Wi-Fi 8) 환경에서 독립적으로 운영되는 다중 액세스 포인트(AP) 네트워크의 분산 최적화를 위한 QA-FedDQN (Quality-Aware Adaptive Federated Deep Q-Network)을 제안한다. 기존 연합 평균화(FedAvg)는 데이터 양만을 기준으로 클라이언트 업데이트를 집계하여 데이터 품질이나 네트워크 이질성을 고려하지 못한다. QA-FedDQN은 데이터 양, 보상 기반 품질, TD-error 기반 네트워크 안정성을 통합한 적응적 집계 전략을 채택한다. 5 회 반복 실험 결과 QA-FedDQN은 FedAvg 대비 전체 평균 1.2 향상과 가장 낮은 표준편차(1.3)로 높은 재현성을 달성하며, 처리량 748.0 Mbps(9.2% 향상), 지연 6.64 ms(13.8% 개선), Fairness  $\sigma=5.7$ 로 최고 네트워크 성능을 보이고, 중앙집중식 대비 98% 빠른 수렴을 달성한다.

### I. 서론

차세대 무선랜 표준인 IEEE 802.11bn (Wi-Fi 8)은 초고밀도 환경에서 극한 신뢰성(Ultra High Reliability)을 목표로 한다[1]. 기업, 공항, 스타디움과 같은 고밀도 환경에서 다수의 독립 운영 AP가 동일 공간에 배치되며, 각 AP는 상이한 트래픽 패턴, 간섭 수준, 사용자 분포를 경험한다. 중앙집중식 제어는 AP 간 조정 오버헤드와 단일 장애점 문제를 야기하며, 독립 학습은 비효율적 자원 활용과 느린 수렴을 초래한다.

기존 FedAvg는 클라이언트가 수집한 데이터 양에만 비례하여 업데이트를 집계한다[2]. 무선 네트워크 환경에서 AP 별 데이터 품질은 크게 상이하며[3], 높은 간섭을 겪는 AP는 많은 데이터를 수집하더라도 낮은 품질의 학습 경험을 제공한다. 심층 강화학습을 연합학습과 결합한 연구는 존재하나[4], 대부분 균일 평균화를 사용하여 클라이언트 품질 차이를 무시한다.

본 연구는 데이터 양, 보상 기반 품질, TD-error 기반 안정성을 통합한 품질 인식 적응적 집계 메커니즘을 제안한다. QA-FedDQN (Quality-Aware Adaptive Federated Deep Q-Network)은 각 AP가 채널 선택,

전송 전력 조정, QoS 전략을 독립 학습하면서 품질 가중 협력적 지식을 공유한다. IEEE 802.11bn MAC 계층 시뮬레이션을 통해 EDCA, OFDMA, A-MPDU, CSR을 포함한 실제 환경을 재현한다[5].

### II. QA-FedDQN

#### 2.1 시스템 아키텍처

각 AP  $i$ 는 Q-네트워크  $Q_{\theta_i}(s, a)$ 를 유지하며 로컬 경험  $(s_t, a_t, r_t, s_{t+1})$ 을 재생 버퍼  $\mathcal{D}_i$ 에 저장한다. 상태 공간은 네트워크 메트릭(큐 길이, 채널 사용률, SINR, 처리량, 지연), MAC 계층 통계(전송 성공률, 프레임 집합화율), Per-AC 큐 길이를 포함한다. 행동 공간은 8 개 채널, 4 단계 전력, 3 가지 QoS 전략의 조합으로 96 개 이산 행동을 형성한다.

#### 2.2 품질 인식 집계

연합학습 라운드  $k$ 에서 서버는  $N$  개의 로컬 모델  $\{\theta_i^k\}_{i=1}^N$ 을 가중 평균하여 글로벌 모델을 집계한다:

$$\theta_g^{k+1} = \sum_{i=1}^N w_i^k \theta_i^k, \quad w_i^k = \frac{\lambda_1 \alpha_i^k + \lambda_2 \beta_i^k + \lambda_3 \zeta_i^k}{\sum_{j=1}^N (\lambda_1 \alpha_j^k + \lambda_2 \beta_j^k + \lambda_3 \zeta_j^k)} \quad (1)$$

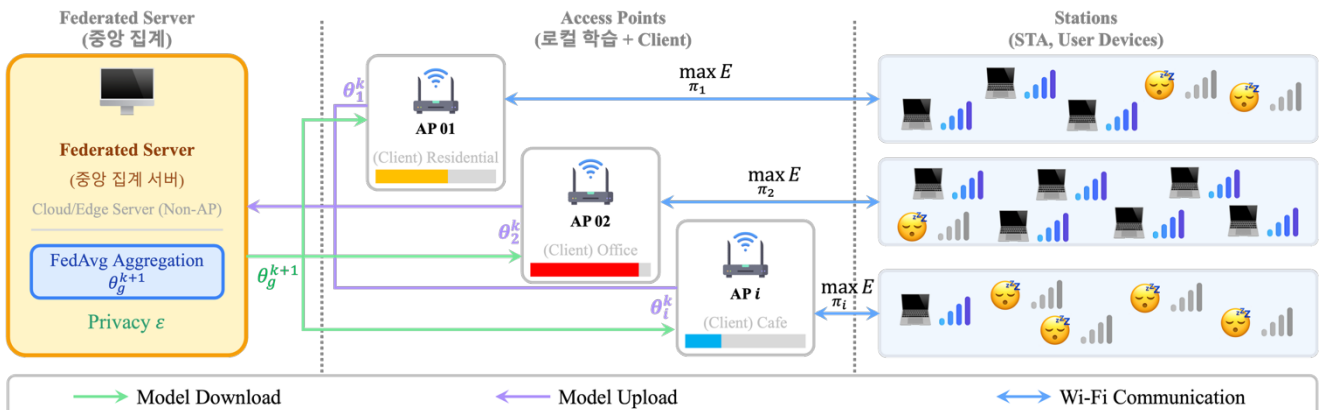


그림 1. QA-FedDQN 시스템 아키텍처. 각 AP는 로컬 DQN 에이전트로 독립 학습하며, 서버는 품질 가중 집계로 글로벌 모델을 업데이트한다.

여기서  $\alpha_i^k = |\mathcal{D}_i|/\sum_j |\mathcal{D}_j|$  는 데이터 양 비율,  $\beta_i^k = \phi_i^k / \max_j \phi_j^k$  는 품질 지표( $\phi_i^k = 0.5 \cdot \bar{r}_i^k + 0.25 \cdot \bar{\theta}_i^k + 0.25 \cdot (1 - \bar{D}_i^k)$ ),  $\zeta_i^k = 1/(1 + \bar{\delta}_i^k)$  는 TD-error 기반 안정성 지표이다. 하이퍼파라미터  $\lambda_1, \lambda_2, \lambda_3$  는 세 기준의 상대적 중요도를 조절한다.

### III. 실험 및 결과

#### 3.1 실험 설정

모든 시나리오는 IEEE 802.11ax enhanced WiFi 환경(8 채널, 20 MHz 대역폭, 4 단계 전송 전력 [10, 15, 20, 23 dBm], 20 스테이션)에서 실행한다. DQN 하이퍼파라미터는 학습률 0.0015, 할인율 0.99, 배치 크기 256,  $\epsilon$ -greedy (1.0→0.005, decay 0.995)로 동일한다. 각 시나리오를 seed 42-46 으로 5 회 반복 실행한다. 중앙집중식은 단일 에이전트가 150 에피소드 학습하며, FedAvg는 3 개 AP가 샘플 수 기반 집계로 50 라운드 학습한다. QA-FedDQN 은 동일한 3 개 AP 로 적응적 가중치 집계( $\lambda_1 = 0.5, \lambda_2 = 0.3, \lambda_3 = 0.2$  \$)를 수행한다. 통신 효율성 시나리오는 35 라운드, 로컬 에피소드 20 으로 설정하고, 이질적 클라이언트 시나리오는 AP 별 로컬 에피소드 수를 차등화(21/15/9)하며, 확장성 시나리오는 AP 수를 6 개로 확장한다.

#### 3.2 성능 비교

표 1. 시나리오별 학습 성능 비교

방법	수렴	최대 보상	전체 평균	공정성 $\sigma$
중앙 집중식	146.0 $\pm 0.0$	907.9 $\pm 2.0$	714.0 $\pm 14.4$	-
FedAvg	2.4 $\pm 0.9$	820.8 $\pm 6.3$	808.8 $\pm 2.3$	6.0 $\pm 0.7$
QA-FedDQN	2.2 $\pm 0.8$	819.8 $\pm 2.3$	810.0 $\pm 1.3$	5.7 $\pm 0.9$
통신 효율성	2.4 $\pm 0.9$	821.4 $\pm 4.9$	809.2 $\pm 1.7$	5.8 $\pm 1.1$
이질성 시나리오	4.4 $\pm 1.8$	822.1 $\pm 3.6$	812.4 $\pm 1.4$	6.4 $\pm 2.0$
확장성 시나리오	2.0 $\pm 0.7$	819.5 $\pm 2.7$	809.0 $\pm 0.8$	7.1 $\pm 0.6$

연합학습 방법은 중앙집중식 대비 98% 빠른 수렴(146 → 2-4 라운드)을 달성하며, QA-FedDQN 은 2.2±0.8 라운드로 FedAvg 대비 8% 빠른 수렴을 보인다. QA-FedDQN 은 전체 평균 표준편차 1.3 으로 가장 높은 재현성을 달성하며, 중앙집중식(71.6)과 FedAvg(2.3) 대비 현저히 낮은 분산을 보인다.




그림 2. 시나리오별 학습 곡선 비교.

그림 2 는 시나리오별 학습 곡선을 시각화하여 나타낸다. 모든 연합학습 시나리오가 초기 3-5 라운드 내 빠른 수렴을 보이며 안정적인 성능을 유지한다. QA-FedDQN(파란색)은 FedAvg(녹색) 대비 더 안정적인 학습 곡선을 보이며, 이질적 클라이언트(주황색)는 가장 높은 평균 보상(812.4)으로 수렴한다. 통신 효율성(빨간색)은 적은 라운드 수에도 불구하고

안정적인 성능을 보인다. 확장성 시나리오(청록색, 6 AP)는 빠른 수렴과 낮은 분산으로 스케일러빌리티를 입증한다. 95% 신뢰구간(음영)이 좁아 높은 재현성을 확인할 수 있다.

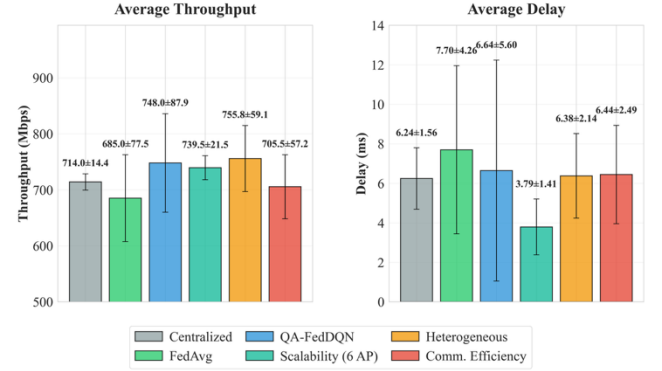


그림 3. 시나리오별 네트워크 성능

그림 3 은 시나리오별 네트워크 성능을 보여준다. QA-FedDQN 은 처리량 748.0 Mbps 로 최고 데이터 전송률을 달성하며 FedAvg 대비 9.2% 향상을 보인다. 지연은 6.64 ms 로 FedAvg(7.70 ms) 대비 13.8% 개선되었다. 이질적 클라이언트 시나리오는 처리량 755.8 Mbps 로 가장 높은 값을 기록하며, 확장성 시나리오는 지연 3.79 ms 로 가장 우수한 응답성을 보인다. Fairness  $\sigma=5.7$ 로 AP 간 가장 공정한 자원 분배를 실현한다.

### IV. 결론

본 논문은 독립 배치 다중 AP WiFi 네트워크를 위한 QA-FedDQN 을 제안한다. 데이터 양, 보상 기반 품질, TD-error 기반 안정성을 통합한 적응적 집계는 FedAvg 의 한계를 극복한다. QA-FedDQN 은 FedAvg 대비 전체 평균 1.2 향상과 가장 낮은 표준편차(1.3)로 높은 재현성을 달성하며, 처리량 748.0 Mbps(9.2% 향상), 지연 6.64 ms(13.8% 개선), Fairness  $\sigma=5.7$  로 최고 네트워크 성능을 보인다. 중앙집중식 대비 98% 빠른 수렴을 달성하며, 확장성과 이질성 환경에서 강건한 성능을 유지한다. 제안 방법은 통신 오버헤드를 최소화하고 공정한 자원 분배를 실현하여 차세대 WiFi 네트워크 분산 최적화에 기여한다.

### ACKNOWLEDGMENT

이 논문은 산업통상자원부 및 산업기술기획평가원 (KEIT)과 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2022R1A2C2005705, 분산 머신러닝 기반 지능형 플러잉 기지국을 위한 AI-MAC 프로토콜, No. RS-2024-00469138, 국산 AI 반도체 기반 비전인식기술 소프트웨어개발도구 개발)

### 참고 문헌

- [1] Galati-Giordano L., Geraci G., Carrascosa M., and Bellalta B., "What will Wi-Fi 8 be? a primer on IEEE 802.11bn ultra high reliability," *IEEE Commun. Mag.*, pp. 126-132, Jan. 2023.
- [2] Li T., Sahu A. K., Talwalkar A., and Smith V., "Federated learning: challenges, methods, and future directions," *IEEE Signal Process. Mag.*, pp. 50-60, May 2020.
- [3] Kim Y. and Kim H., "A survey on fairness provision schemes for federated learning networks," *J. Korean Inst. Commun. Inf. Sci.*, pp. 677-680, June 2023.
- [4] Hoang D. T., Huynh N. V., Nguyen D. N., Hossain E., and Niyato D., "Deep Reinforcement Learning for Wireless Communications and Networking," Wiley-IEEE Press, 2023.
- [5] IEEE Standard 802.11be-2024, "IEEE standard for information technology - wireless LAN MAC and PHY specifications amendment 2: enhancements for extremely high throughput (EHT)," May 2024.