

# 무선 네트워크 환경에서 DQN을 활용한 MAC 프로토콜 응용 사례

박준영, 나웅수\*

국립 공주대학교

jjunyoung99@gmail.com, \*wsna@kongju.ac.kr

## Applications of DQN-Based MAC Protocols in Wireless Networks

Park Jun Young, Na Woong Soo\*

Kongju National University.

### 요약

본 논문은 무선 및 모바일 트래픽의 급격한 증가로 인해, 밀집 환경에서 제한된 무선 자원을 효율적으로 공유하기 위한 MAC (Medium Access Control) 프로토콜 설계의 중요성이 점점 커지고 있다. 최근에는 사전 채널 모델 없이도 동적인 네트워크 환경에 적응할 수 있는 심층 강화학습 기법, 특히 Deep Q-Network(DQN)를 이용하여 MAC 동작을 지능적으로 최적화하려는 연구가 활발히 진행되고 있다. 본 논문에서는 DQN 기반 MAC 프로토콜 설계에 관한 기존 연구들을 WLAN & Wi-Fi, IoT & WSN, Heterogeneous Wireless Networks의 세 가지 도메인으로 분류하여 체계적으로 조사하였다.

### I. 서론

무선 및 모바일 단말의 보급 확산과 함께 전체 무선 네트워크 트래픽은 지속적으로 증가하고 있으며, 특히 밀집 환경에서 제한된 무선 자원을 효율적으로 공유하기 위한 MAC(Medium Access Control) 프로토콜 설계의 중요성이 더욱 커지고 있다 [1]. 네트워크에 접속하는 노드 수가 증가 할수록 채널 경쟁이 심화되어 충돌 확률 증가에 따른 처리량 저하 [2], 전송 지연 증가 [3,4], 그리고 채널 접근의 비공정성 문제가 발생한다 [5]. 이러한 성능 저하는 단순한 물리 계층 링크 품질만으로 설명되기 어렵고, 트래픽 패턴, 경쟁 강도, 재전송 동작, 백오프 파라미터 등 MAC 계층의 의사결정이 핵심적인 영향을 미친다.

기존의 규칙 기반 MAC은 구현이 단순하다는 장점이 있으나, 트래픽과 채널 상태가 시시각각 변화하는 환경에서 최적의 성능을 항상 보장하기는 어렵다. 예를 들어 큰 contention window(CW)를 사용하면 충돌은 감소 할 수 있으나 채널 활용률이 저하되고, 반대로 작은 CW를 사용하면 충돌과 재전송이 증가하여 지연과 손실이 커진다. 즉, 고정된 규칙만으로는 다양한 네트워크 상황에 효과적으로 대응하기 어렵다.

이러한 한계를 극복하기 위한 대안으로 강화학습은 MAC 계층의 의사결정을 데이터 기반으로 적응적으로 최적화할 수 있는 유망한 방법으로 주목받고 있다. 강화학습은 사전 채널 모델이나 트래픽 분포에 대한 가정 없이도 관측과 보상을 통해 정책을 점진적으로 개선할 수 있으며, 트래픽 변동과 간섭·충돌의 불확실성이 큰 무선 네트워크 환경에 특히 적합하다. 그중에서도 Deep Q-Network(DQN)은 심층신경망을 이용해 대규모 상태 공간에서 행동가치함수를 근사함으로써 기존 Q-learning의 Q-table 확장 성 한계를 극복한다 [9,10]. 이를 통해 CW 조정, RTS/CTS 제어, 전송 시점 선택, 다중 채널 선택 등 다양한 MAC 제어 문제를 학습 기반으로 해결할 수 있다.

본 논문은 DQN 기반 MAC 프로토콜 설계에 관한 기존 연구들을 체계적으로 정리하고, 적용 환경과 설계 목표에 따른 연구 흐름을 비교·분석하는 것을 목표로 한다. 이를 위해 기존 연구를 WLAN 및 Wi-Fi, IoT 및

WSN, 그리고 Heterogeneous Wireless Networks의 세 가지 도메인으로 분류하여 각 환경에서 다루는 MAC 문제와 DQN 설계 방식을 중심으로 조사한다.

### II. 본론

#### A. WLAN & Wi-Fi

WLAN 및 Wi-Fi 시스템은 IEEE 802.11 표준을 기반으로 CSMA/CA 경쟁 접근 방식을 사용하므로, 네트워크 밀도가 증가할수록 충돌 확률 증가와 처리량 저하 문제가 두드러진다. 이를 해결하기 위해 최근 연구들은 DQN을 활용하여 contention window(CW), RTS/CTS 사용 여부, 전송 시점 등을 동적으로 조정하는 MAC 최적화 기법을 제안하고 있다.

논문 [6]은 중앙집중형 DQN 애이전트를 통해 네트워크 혼잡도와 트래픽 상태를 고려하여 MAC 파라미터를 제어함으로써 기존 CSMA/CA 대비 높은 처리량과 안정적인 QoS를 달성하였다. 또한 [7]은 MAC 프로토콜을 기능적 블록 단위로 분해하고 DQN을 통해 상황에 맞는 블록 조합을 선택하는 DeepMAC 구조를 제안하였다. 한편 [8]과 [9]는 OFDMA 환경 및 분산 학습 시나리오에서 DQN과 연합 학습을 적용하여 지연, 처리량, 공정성 측면에서 유의미한 성능 향상을 보였다.

#### B. IoT & WSN

IoT 및 WSN 환경은 초저전력 단말, 불규칙 트래픽, 밀집 다중 흡 구조 등으로 인해 기존 MAC 기법의 한계가 더욱 두드러진다. 이에 따라 최근 연구들은 다중 MAC 파라미터 공동 최적화나 방향성 통신 및 에너지 제약을 고려한 DQN 기반 MAC 설계를 제안하고 있다.

논문 [10]은 방향성 범 기반 IoT 환경에서 전송 방향과 MAC 접근을 동시에 학습하는 DQN 프레임워크를 제안하여 기존 방식 대비 높은 처리량과 안정적인 링크 성능을 달성하였다. 또한 [11]은 밀집 multi-hop WSN에서 CW 및 백오프 파라미터를 공동 최적화하는 중앙집중형 DQN 구조를 제안하여 처리량 증가와 지연 감소를 동시에 달성하였다. 백스캐터 통신 환경을 다룬 [12]는 분산 DRL 기반 MAC을 통해 충돌을 효과적으로

줄이고 Wi-Fi와의 공존 성능을 향상시켰다.

#### C. Heterogeneous Wireless Networks

Heterogeneous Wireless Network 환경에서는 서로 다른 MAC 프로토콜이 동일 채널을 공유함에 따라 복잡한 상호 간섭 문제가 발생한다. 이러한 환경에서는 상대 네트워크의 동작을 명시적으로 알 수 없기 때문에 관측 기반으로 행동을 학습하는 DQN 접근이 효과적인 대안으로 제시된다. 논문 [13]과 [14]는 DQN 및 그 변형 구조를 이용하여 Wi-Fi, TDMA, ALOHA가 혼재된 환경에서도 근사 최적 수준의 공존 성능을 달성할 수 있음을 보였다. 특히 reward backpropagation 및 ResNet 기반 신경망 구조를 통해 수렴 속도와 표현력을 개선하였다. 또한 [15]는 다중 채널 환경으로 확장된 DQN 기반 MAC을 제안하여 HetNet 구조의 실용적 확장 가능성을 입증하였다.

### III. 결론

본 논문은 무선 네트워크에서 DQN을 활용하여 MAC 프로토콜 성능을 향상시키는 기존 연구들을 WLAN & Wi-Fi, IoT & WSN, 그리고 Heterogeneous Wireless Networks의 세 가지 도메인으로 분류하여 조사하였다. WLAN/Wi-Fi 분야에서는 DQN 기반 CW 제어, RTS/CTS 결정, MAC 기능 블록 선택, 연합 학습 기반 분산 MAC 설계를 통해 충돌 감소와 채널 활용률 향상을 달성하였다. IoT/WSN 분야에서는 초저전력 단말과 비정형 트래픽, 밀집·다중 흡 구조를 고려하여 방향성 접근, 다중 MAC 파라미터 공동 최적화, 백스캐터 환경 공존을 중심으로 에너지 효율과 링크 신뢰성을 개선하였다. 또한 HetNet 환경에서는 관측 기반 DQN 및 변형 구조를 적용하여 모델 정보 없이도 상이한 MAC 간 공존 성능을 효과적으로 향상시킬 수 있음을 보였다. 그러나 대부분의 연구는 단순화된 시뮬레이션 환경과 제한된 네트워크 규모를 가정하고 있어 실제 환경에서의 일반화 성능과 안정성 검증이 충분하지 않다는 한계가 있다. 또한 단일 목적 최적화나 단일 에이전트 설정에 의존하는 경우가 많아 대규모 분산 네트워크에서의 비정상성 문제를 충분히 다루지 못하고 있다.

향후 연구에서는 부분 관측 환경에서의 강건한 학습, 다중 에이전트 기반 협력·경쟁 MAC 설계, 처리량·지연·공정성·에너지 효율을 동시에 고려하는 다목적 최적화, 그리고 테스트베드 기반 실증을 통한 현실 적용성 검증이 중요한 과제로 남아 있다. 이러한 과제들이 해결된다면 DQN 기반 MAC 설계는 차세대 무선 네트워크에서 핵심적인 지능형 매체 접근 기술로 발전할 수 있을 것이다.

### ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학 ICT 연구센터육성지원사업(IITP-2026-RS-2022-00156353) 및 2025년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(RS-2019-NR040074)

### 참 고 문 헌

- [1] T. S. Rappaport et al., "Wireless Communications and Applications Above 100 GHz: Opportunities and Challenges for 6G and Beyond," in IEEE Access, vol. 7, pp. 78729–78757, 2019.
- [2] C. Kai, S. Zhang and L. Wang, "Impacts of packet collisions on link throughput in CSMA wireless networks," in China Commun., vol.

15, no. 3, pp. 1–14, Mar. 2018.

- [3] G. Wang, Y. Shu, L. Zhang, and O. W. W. Yang, "Delay analysis of the IEEE 802.11 DCF," 14th IEEE Proc. PIMRC 2003, vol. 2, pp. 1737–1741, Beijing, China, 2003.
- [4] T.-S. Ho and K.-C. Chen, "Performance analysis of IEEE 802.11 CSMA/CA medium access control protocol," in Proc. PIMRC '96 – 7th Int. Symp. Personal, Indoor, and Mobile Commun., vol. 2, pp. 407–411, Taipei, Taiwan, 1996.
- [5] S. Lu, V. Bharghavan, and R. Srikant, "Fair scheduling in wireless packet networks," in IEEE/ACM Trans. Netw., vol. 7, no. 4, pp. 473–489, Aug. 1999.
- [6] K. Aruga and T. Fujii, "MAC protocol adaptation method in coordination with application," 2024 ICAIIC, pp. 463–466, Osaka, Japan, 2024.
- [7] H. B. Pasandi and T. Nadeem, "MAC protocol design optimization using deep learning," 2020 ICAIIC, pp. 709–715, Fukuoka, Japan, 2020.
- [8] J. Lei, L. Li, and Y. Wang, "QoS-oriented media access control using reinforcement learning for next-generation WLANs," Comput. Netw., vol. 219, p. 109426, 2022.
- [9] L. Zhang, H. Yin, Z. Zhou, S. Roy, and Y. Sun, "Enhancing wifi multiple access performance with federated deep reinforcement learning," 2020 IEEE 92nd VTC2020-Fall, pp. 1–6, Victoria, BC, Canada, 2020.
- [10] N. Kim, W. Na, D. S. Lakew, N.-N. Dao, and S. Cho, "DQN-based directional MAC protocol in wireless ad hoc network in internet of things," in IEEE Int. Things J., vol. 11, no. 7, pp. 12918–12928, Apr. 2024.
- [11] J. Lei, D. Tan, X. Ma, and Y. Wang, "Reinforcement learning based multiparameter joint optimization in dense multi-hop wireless networks," Ad Hoc Netw., vol. 154, no. 103357, Mar. 2024.
- [12] X. Cao, Z. Song, B. Yang, X. Du, L. Qian, and Z. Han, "Deep reinforcement learning MAC for backscatter communications relying on wi-fi architecture," 2019 IEEE GLOBECOM, pp. 1–6, Waikoloa, HI, USA, 2019.
- [13] Y. Yu, S. C. Liew, and T. Wang, "Carrier-sense multiple access for heterogeneous wireless networks using deep reinforcement learning," 2019 IEEE WCNCW, pp. 1–7, Marrakech, Morocco, 2019.
- [14] Y. Yu, T. Wang, and S. C. Liew, "Deep-reinforcement learning multiple access for heterogeneous wireless networks," in IEEE J. Sel. Areas in Commun., vol. 37, no. 6, pp. 1277–1290, Jun. 2019.
- [15] X. Ye, Y. Yu, and L. Fu, "MAC protocol for mMulti-channel heterogeneous networks based on deep reinforcement learning," GLOBECOM 2020, pp. 1–6, Taipei, Taiwan, 2020.