

기계학습을 활용한 이종망에서의 Wi-Fi 성능 개선 연구 동향 분석

¹*강영명

Research Trends in Wi-Fi Performance Improvement in Coexistence Networks with Machine Learning

¹*Young-myung Kang

요약

최근 혁신적으로 발전하고 있는 기계학습은 다양한 최적화 문제를 해결할 수 있는 중요한 기술이 되었다. 본 논문에서는 기계학습을 활용하여 이종망의 채널 공유화 문제를 해결하는 최신 연구 논문들을 소개하고 주된 기술의 특성을 분석하여 향후 연구 방향에 대해 가이드를 제시한다. 기존 연구들은 대체로 온라인 및 오프라인으로 빠른 학습이 가능한 Q-learning을 활용하는 경우가 많았다. 반면 다양한 공존 시나리오를 고려하지 않거나 망 성능에 큰 영향을 줄 수 있는 기계학습 컨트롤러의 위치에 대한 고려는 제한적이었다. 이런 단점을 극복할 수 있는 유력한 방안으로는 ITU에서 제안한 기계학습용 논리적 망구조를 기반으로 망 환경 변화에 따라 기계학습 알고리즘을 선택적으로 사용할 수 있는 방법이 있다.

Abstract

Machine learning, which has recently innovatively developed, has become an important technology that can solve various optimization problems. In this paper, we introduce the latest research papers that solve the problem of channel sharing in heterogeneous networks using machine learning, analyze the characteristics of mainstream approaches, and present a guide to future research directions. Existing studies have generally adopted Q-learning since it supports fast learning both on online and offline environment. On the contrary, conventional studies have either not considered various coexistence scenarios or lacked consideration for the location of machine learning controllers that can have a significant impact on network performance. One of the powerful ways to overcome these disadvantages is to selectively use a machine learning algorithm according to changes in network environment based on the logical network architecture for machine learning proposed by ITU.

Keywords: Coexistence, Wi-Fi, LTE-LAA, Performance, Machine Learning

¹* 성결대학교 컴퓨터공학과 교수, 교신저자, ykang@sungkyul.ac.kr

I. 서론

Wi-Fi와 이동통신(즉, Cellular Network)이 공존하는 환경에서 서로의 간섭을 최소화해서 전송 성능을 개선하는 방안은 지속적으로 활발하게 연구되어 왔다. 이러한 노력의 결과로 면허대역(Licensed Band)을 사용하는 LTE와 비면허대역(Unlicensed Band)을 사용하는 Wi-Fi와의 공존 문제는 간섭 제어를 위한 혁신적 기술의 발전으로 기가(Gbps) 단위의 전송 성능을 보여주는 수준에 이르렀다. 그러나, 비면허대역에서 Wi-Fi와 이동통신(ex., LTE-U/LTE-LAA)이 공존하는 환경에서는 이중 전송간 충돌로 인해 최대 90%에 이르는 전송 성능 저하가 발생할 수 있다 [1, 2]. 따라서 비면허대역에서의 이중 기술간 공정한 채널 공유화는 여전히 해결해야 할 중요한 문제로 인식되고 있다 [3].

최근 혁신적으로 발전한 인공지능 기술 [4, 5]은 다양한 최적화 문제를 해결할 수 있는 중요한 기술로 각광받고 있다. 본 논문에서는 기계학습(Machine Learning)을 활용하여 이중망의 채널 공유화 문제를 해결하는 연구 논문들을 소개하고 주된 기술의 특성을 분석하여 이를 바탕으로 개선안 및 향후 연구 방향에 대해 가이드를 제시한다.

이해를 돕기 위해 간단히 기계학습에 대해 설명한다. 기계학습 시스템 종류는 매우 많지만 큰 범주에서 보자면 사람의 감독하에 훈련을 하는지 여부를 기준으로 지도(Supervised), 비지도(Unsupervised), 강화(Reinforcement) 학습으로 구분할 수 있다 [4, 5].

지도 학습은 사람이 정답(레이블)이 포함된 데이터를 알고리즘에 제공하여 훈련을 시키는 방식이다. 분류(Classification)와 회귀(Regression) 분석이 대표적인 작업이며 K-nearest Neighbors, Linear Regression, Logistic Regression, Support Vector Machine, Decision Tree, Random Forest 등의 다양한 학습 알고리즘이 존재한다. 알고리즘의 성능지표로는 대체로 오차 행렬(Confusion Matrix)을 통해 정밀도(Precision)와 재현률(Recall)을 사용한다.

비지도 학습은 알고리즘에 제공된 데이터에 정답이 없는 것이 특징이다. 즉, 기계 스스로 학습을 학습해야 한다. 이 방식에는 군집(Clustering), 시각화(Visualization), 차원 축소(Dimensionality Reduction), 연관 규칙 학습(Association Rule Learning) 등이 대표적인 작업이며 관련해서 K-means, DBSCAN, Hierarchical Cluster Analysis, Outlier Detection, Kernel 등 다양한 알고리즘이 존재한다. 비지도 학습은 정해진 정답이 없으므로 알고리즘의 성능을 단순히 정확성이라는 지표로 판단하기 어렵다. 군집 알고리즘의 예를 들면 군집이 잘 되었다고 판단하는 기준은 군집간 분산은 최대가 되고 군집 내 분산은 최소가 되는 것이다.

마지막으로 강화 학습은 지도 및 비지도 방식과는 다소 다르게 동작한다. 강화 학습에서는 에이전트(Agent, 학습 시스템)가 환경을 관찰(Observation)하고 이 정보(Information)를 바탕으로 현재 상태(State)에서 정책(Policy)을 기준으로 행동(Action)을 실행하고 그 결과에 따른 보상(reward or penalty)을 받는 방식이다. 주로 실시간 결정을 요하는 작업에 사용되며 대표적인 알고리즘으로는 Monte Carlo, Q-learning, State-Action-Reward-State-Action(SARSA) 등이 있다. 강화학습에서는 알고리즘의 수행결과로 보상을 최대화하는 것을 성능 평가의 기준으로 삼는다.

위에서 살펴본 기계학습 기법을 통해 이중망에서 전송 성능 향상을 목표로 하는 연구주제는 다음의 4가지 정도로 요약된다 [6];

- 공정한 채널 공유 (Fair Channel Sharing),
- 망 관찰/관리 (Network Monitoring),
- 신호 분류 (Signal Classification),
- 협력 네트워킹 (Cooperative Networking).

우선 이중망에 기계학습을 적용하는 시나리오 측면에서 살펴보면 다수의 관련 연구들은 Wi-Fi 성능 저하를 방지하기 위해 LTE의 동작을 최적화하였고 [7], 일부는 그림 1과 같이 LTE 및 Wi-Fi에 모두 기계학습을 적용(i.e., 기지국 또는 Wi-Fi AP에 ML Controller 또는 Agent 탑재)하였다. 공존 시나리오를 좀 더 세부적으로 나누어 보면 다음의 5가지로 구분할 수 있다. 첫째, 그림 1-(a)와 같이 중앙집중식 컨트롤러에서 기계학습을 수행하여 LTE 및 Wi-Fi 모두를 관리하는 방식이다. 둘째, 그림 1-(b)와 같이 하나의 중앙집중식 컨트롤러가 LTE 기지국들을 대상으로 기계학습으로

통제하는 방식이다. 기계학습은 LTE 쪽에서만 진행되고 Wi-Fi 망은 독립적으로 운용된다. 셋째, 그림 1-(c)와 같이 각각의 LTE 기지국에서 독립적으로 동작하는 분산적 기계학습 방식이 있다. 넷째, 그림 1-(d)에서 보는 바와 같이 LTE와 Wi-Fi 망에서 각각 중앙집중식 기계학습을 독립적으로 진행하고 중앙 컨트롤러 사이에서 서로 정보를 교환한다. 마지막으로, 그림 1-(e)와 같이 Wi-Fi AP 및 LTE 기지국 각각에 모두 기계학습 컨트롤러를 설치하여 독립적인 기계학습을 진행하는 형태이다. 이러한 다양한 공존 시나리오를 복합적으로 대응하려는 기계학습 망구조에 대해서는 본문 III 장에서 좀 더 자세히 설명한다.

한편 기존 이중망의 성능 향상을 위해 도입된 기계학습 기법들을 전체적으로 분석해 보면 다음의 두 가지 특성으로 요약할 수 있다.

첫째, 대다수 관련 연구들은 강화학습 (Reinforcement Learning) 또는 심화지도학습 (Deep Supervised Learning)을 적용한 경우가 많다 [7-10]. 특히, 그 중에서도 Q-Learning 을 적용한 사례가 많은데 이는 현재 상태를 바탕으로 수집된 정보를 기반으로 행동을 취하는 Q-learning 의 특성이 매 순간 전송 스케줄링 결정을 내려야 하는 망의 동작방식과 잘 어울리기 때문이다. 관련하여 광범위한 기계학습 모델 조사를 진행한 [6]에서 이중망의 채널 공유와 관련하여 분석한 논문 29 개 중 22 개 (약 76%)가 Q-learning 또는 Deep Q-learning 을 활용한 것이었다.

둘째, 망 전체적인 지연을 고려하기보다는 지역적인 최적화 관점에서 기계학습을 적용하였다. 일반적으로 이중망은 중앙집중식 또는 분산식으로 운용될 수 있기 때문에 기계학습 컨트롤러의 위치에 따른 망 지연을 고려해야 한다. 한편 중앙집중식 컨트롤러를 사용하는 경우 고성능 컴퓨팅 오버헤드 문제를 해소해야 하며 분산환경으로 운용되는 컨트롤러의 경우 망의 실시간 변화 (Network Dynamics)에 대한 고려가 필요하다.

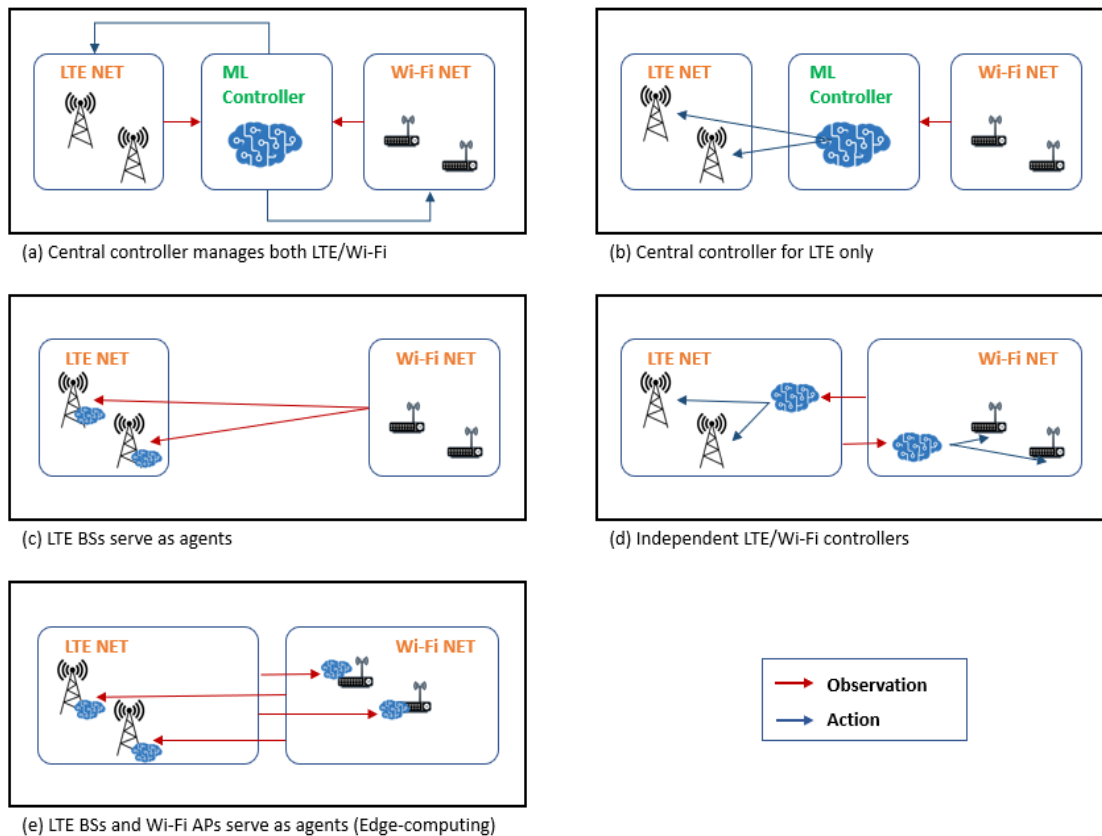


Figure 1. Types of ML implementations in LTE/Wi-Fi Coexistence Scenarios.

논문은 다음과 같이 구성된다. 본문 II 장에서는 Wi-Fi와 이동통신이 공존하는 이중망에서 전송 성능 개선을 위한 다양한 관련 연구를 소개한다. III 장에서 ITU에서 제안한 기계학습을 고려한 망 구조(Architecture)를 살펴보고 이 망구조에서 지연을 고려한 기계학습 적용 방안에 대해 논의한다. 마지막으로 IV 장에서 결론을 맺는다.

II. 기계학습을 적용한 이중망 성능 개선 연구

2.1 공정 채널 공유 기법 (Fair Channel Sharing)

Wi-Fi와 LTE-U 사이에 전송 충돌을 피하고 채널 점유를 효과적으로 하기 위해 다수의 연구들이 진행되었다. 대부분의 연구는 Carrier Sense Adaptive Transmission (CSAT)의 효과를 극대화하기 위해 Q-Learning을 이용하며 Duty-Cycle 성능을 개선하는 것에 초점을 맞추고 있다 [8-10]. 그림 2는 CSAT에 대한 기본 동작방식을 보여주고 있다. 정해진 Duty-Cycle에서 Wi-Fi 전송을 고려하여 LTE 전송을 On 또는 Off하여 이중 전송 간 충돌을 회피한다. 이 방식에서는 기계학습 컨트롤러에는 입력으로 들어오는 간섭 수준과 요구되는 전송량, 그리고 전송의 시간 공정성 등의 관찰 정보 (Observation Info.)를 바탕으로 최적의 LTE 전송 간격을 조절한다.

이와 비슷한 방법으로는 그림 3에서 보는 것과 같이 LTE가 빈 서브프레임 (ABS, Almost Blank Sub-frame)을 보내 Wi-Fi 전송을 방해하지 않는 방식이다. 그림 3에서 기계학습 컨트롤러는 Wi-Fi와 LTE의 전송 요구량 대비 만족도와 전송 기회의 공정성을 기준으로 ABS 패턴을 최적화한다. CSAT 및 ABS 방식 모두 Wi-Fi 전송을 보호하기 위해 LTE 전송을 연기한다는 공통점이 있다.

한편 LTE-LAA (LTE-Licensed Assisted Access)와 Wi-Fi 공존 문제는 [11]에서 다루고 있다. [11]은 그림 4에서 보는 바와 같이 Listen Before Talk (LBT) 기반의 채널 접속 방식의 성능 효율화를 위해 Q-Learning에 기반한 기계학습으로 관련 파라미터를 조정한다. 이 경우 기계학습 컨트롤러 입력은 전송간 충돌확률 (Collision probability), 전송 처리량 (Throughput), 공정성 지표 (Fairness Index), 경쟁하는 Wi-Fi 및 LTE 단말 개수 등이 있으며, 이 정보를 기반으로 충돌확률을 줄일 수 있는 CW (Contention Window), TXOP duration, 채널 선택 (Channel Selection) 등을 결정하여 실행 (Action)에 옮긴다.

앞서 설명한 바와 같이 LTE-U/LTE-LAA와 Wi-Fi가 공존하는 이중망에서의 공정 채널 공유를 통한 전송 성능 향상을 위한 연구는 꾸준히 연구되어 왔다. 이와는 별도로 다루어져야 할 연구 분야는 현재 전세계적으로 활발히 보급되고 있는 5G NR (New Radio)과 꾸준히 진화하고 있는 Wi-Fi 개정안 (IEEE 802.11 Family amendments)들 사이의 공존문제이다. 비면허대역에서 작동하는 NR-U (New Radio-Unlicensed)와 Wi-Fi 신호는 기존의 방식과는 다르게 접근되어야 한다. 예를 들어, NR 신호는 LTE 신호보다 높은 대역대에서 작동하므로 신호 감쇄가 LTE에 비해 더 심하다 [12-14].

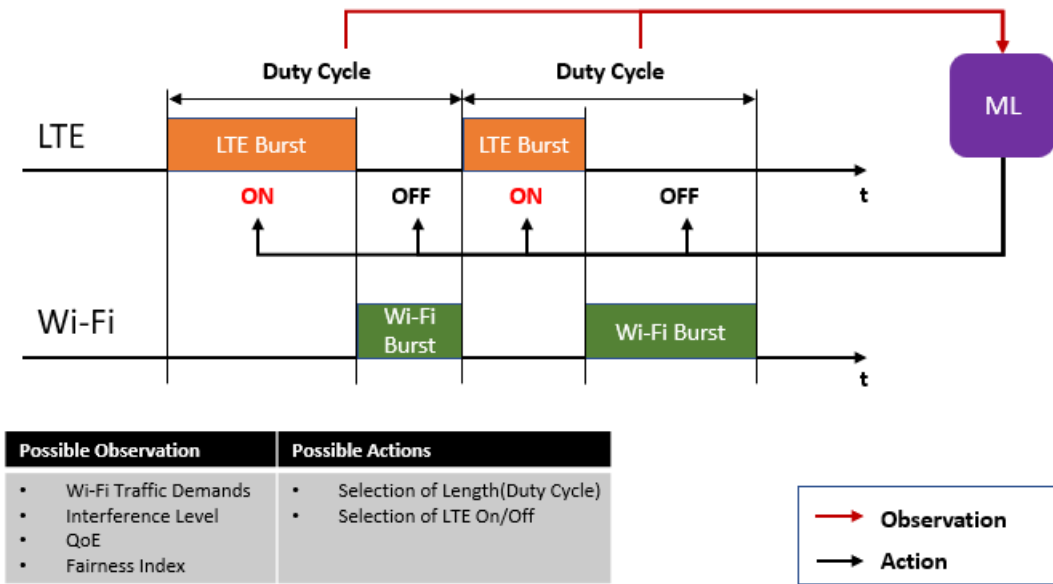


Figure 2. Enhancing the CSAT mechanism with Machine Learning

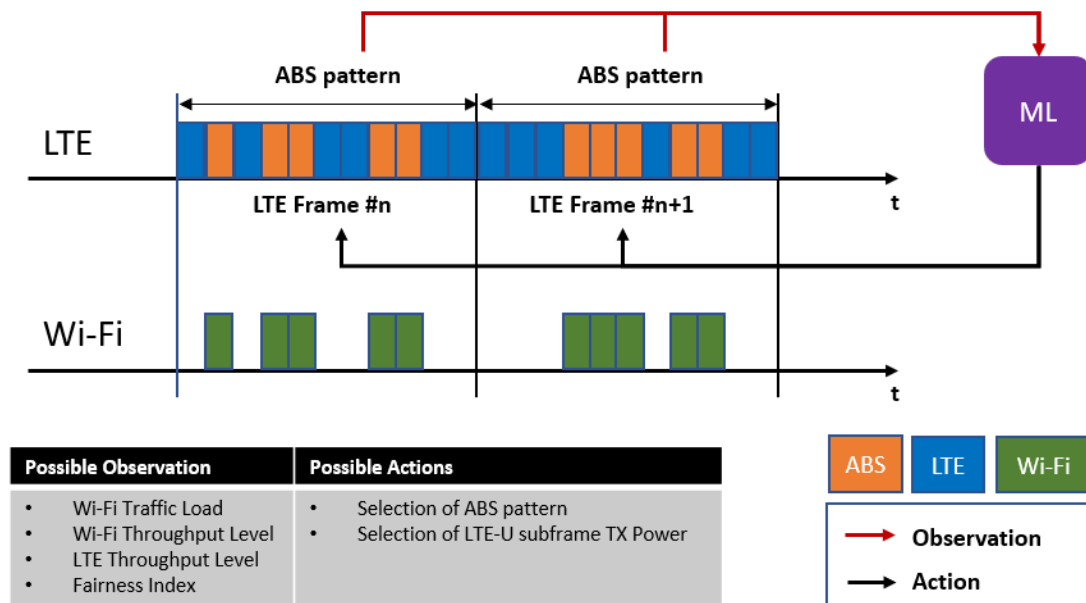


Figure 3. Enhancing the LTE-U ABS mechanism with Machine Learning

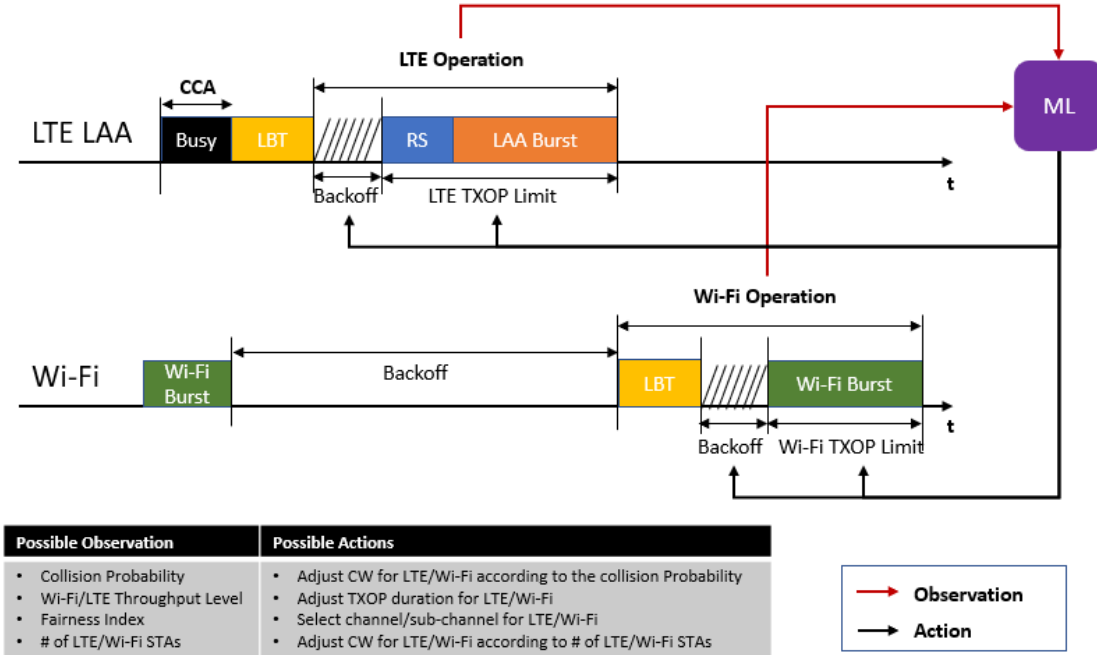


Figure 4. LTE-LAA LBT function

2.2 기타 이종망에서의 Wi-Fi 성능향상 기법들

이종망에서의 효율적인 망 관찰/관리 (Network Monitoring)는 다양한 RAT (Radio Access Technology)가 혼재하는 상황에서 경쟁하는 STA(Station)의 규모에 따라 RAT를 적절하게 조정하는 방식을 말한다. [15]는 Q-learning 및 Double Q-learning을 사용해서 Wi-Fi STA이 채널을 점유하는 시간을 파악하고 이를 바탕으로 최적의 채널을 선택하는 방법을 제안했다. 추가적으로 LTE-A 전송 파워를 조절하여 Wi-Fi STA에 미치는 간섭을 최소화하였다.

신호 분류 (Signal Classification)를 통해 이종망에서 서로에게 간섭을 최소화하는 방안도 활발한 연구영역에 해당한다. [16]의 연구에서는 데이터 프레임 전송간격(Inter-frame spacing statistics)을 측정하여 Wi-Fi 망의 데이터 요구량 통계를 측정하는 방안을 제안하였다.

Wi-Fi와 Li-Fi (Light Fidelity) 또는 VLC (Visible Light Communication)과의 하이브리드 망 구성은 이종망의 또다른 형태이다. 이와 관련된 연구를 살펴보면, [17]에서는 Q-learning을 적용한 중앙집중식 컨트롤러를 통해 Wi-Fi-VLC 최적화를 시도한 결과 처리량 향상을 이루었다. 아래 표 1은 각각 참고문헌에서 적용한 기계학습 알고리즘 및 관련 파라미터를 정리하여 보여주고 있다.

Table 1. Adopted ML Algorithms in Referenced paper in section 2.2

Ref #	ML Category	ML Algorithm	Application (parameter)	Improvement
[15]	Reinforcement	Q-learning, Double Q-learning	Estimate channel occupancy time	Throughput Improvement
[16]	Supervised	CNN	Wi-Fi Saturation Detection - Analyze inter-frame spacing statistics	High classification accuracy
[17]	Reinforcement	Q-learning	Select AP for Wi-Fi offloading	Throughput Improvement

III. ITU 의 기계학습 적용 망 구조

3.1 ITU 기계학습 적용 미래 망 구조 분석

ITU 는 그림 5 에서 보여주는 것과 같이 기계학습을 고려한 논리적인 미래 망 구조를 제안하였다 [18]. 이 구조의 특징은 기계학습 기능을 지원하기 위한 요구조건들을 기존 망 형태 (예, 3G/4G/5G/IEEE 802.11)에 제한없이 적용 가능(Underlay Network-agnostic)하다는 것이다. 이 논리적 망 구조는 크게 3 가지 부시스템(subsystem)으로 구성된다.

첫째, 관리 부시스템 (Management subsystem)은 기존 망에 적용할 기계학습 서비스를 조율하는 역할을 한다. 관리 부시스템은 적용 시나리오(Adoption of Service Scenario), 정책(Policy), 제한요소(Limitations) 등을 기술한 INTENT 파일과 이를 실제로 적용하여 기계학습 서비스를 조율하는 MLFO (Machine Learning Function Orchestrator)로 구성된다. 시스템이 초기화될 때 가장 먼저 INTENT 가 MLFO 로 전달되어 실제 서비스할 기계 학습 모델을 적용한다.

두번째, 기계 학습 파이프라인 부시스템(ML pipeline subsystem)은 기존 망에 오버레이 형태로 적용할 수 있는 논리적인 파이프라인에 해당한다. 여기서 기계학습 파이프라인을 기존 망에 오버레이 형태로 적용하려는 이유는 망에서 작동하는 장비(Network Element)에 탑재되는 기능(Network Function)을 최대한 동적으로 결정(Network Function Virtualization)하려는 유연한 망 구조 특성을 반영한 것이다. 이러한 오버레이 구조가 잘 작동하기 위해서는 기존 망과 연동을 위한 구체적인 프로토콜과 API 들이 명확하게 정의되어야 한다.

세번째, 기계학습 샌드박스 부시스템 (ML sandbox subsystem)은 기계학습 파이프라인 부시스템에서 전달받은 망 환경 변화를 반영하여 학습을 진행한다. 망 환경 변화에 따른 기계학습 정책 조율은 모두 MLFO 에 의해 이루어진다.

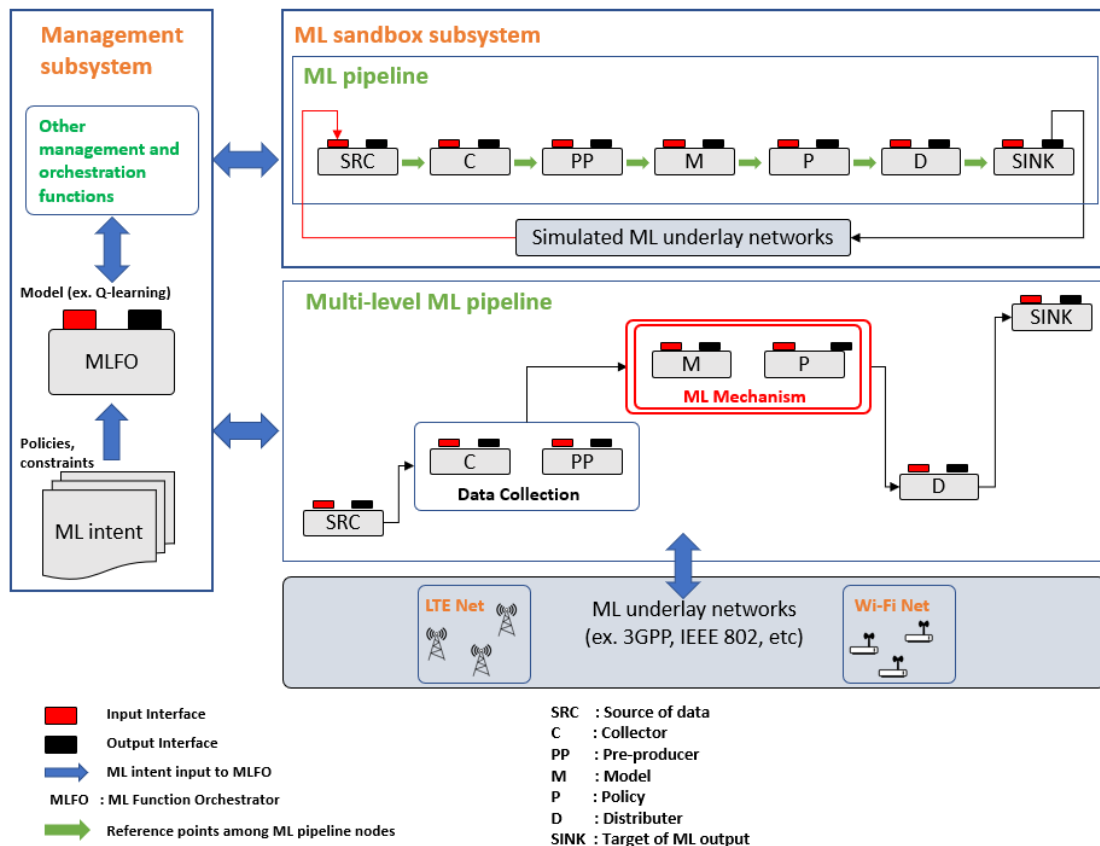


Figure 5. Unified ML-aware Architecture for future Networks

3.2 Discussion

기계학습 컨트롤러는 중앙집중식 혹은 분산환경에서 운용될 수 있으며 형태에 따라 LTE 기지국 또는 Edge에 해당하는 Wi-Fi AP에도 설치될 수 있다. 중앙집중식은 캠퍼스나 공항 또는 회사에서 전체 AP를 관리하는 경우에 해당하고 분산형은 개별 가구에서 각자의 AP를 독립적으로 운용하는 형태에 해당한다. 일반적으로 통신사에서는 기지국 시스템을 운용하는 동시에 Wi-Fi AP도 제공하기 때문에 이들 각각에 기계학습 컨트롤러를 탑재하는 것이 가능하다.

기계학습 기능을 탑재한 컨트롤러 (또는 Agent)의 위치는 지연 관점에서 망 전체 성능에 큰 영향을 줄 수 있다. 문제가 되는 것은 기계학습의 연산결과가 유효한 시간내에 실행되는지에 달려 있다. 지연이 큰 망구조에서는 기계학습 결과 실행이 늦어지거나 혹은 과거 데이터 참조로 인한 지속적인 성능저하가 발생할 수 있다는 점이다.

이러한 문제를 해소할 수 있는 방안으로는 앞서 설명한 ITU의 단일형 망 구조를 기반으로 하되 망 운영 방식(중앙집중 vs. 분산)과 환경 변화에 맞추어 기계학습 알고리즘을 선택적으로 사용하게 하는 것이다. 이런 방식을 적용하면 망 구조를 플랫폼화 하여 다양한 시스템에 쉽게 이식할 수 있는 장점이 생긴다. 즉, 다양한 망에 동일한 방식으로 운용되는 기계학습 알고리즘을 탑재함으로써 확장성이 크다. 다만 지나치게 빠르게 정책이나 모델을 변경하는 것은 망 전체 성능에 또 다른 영향을 미칠 수 있기 때문에 알고리즘 변경주기에 대한 추가 최적화 연구가 필요하다.

IV. 결론

이동통신과 Wi-Fi 기술이 공존하는 이중망의 성능 향상을 위해 다양한 기계학습 기법들이 도입되었다. 기존 연구들은 현재 상태에서 취득한 정보를 기준으로 다음 행동의 최대 보상을 목적으로 하는 Q-learning을 활용하는 사례가 많았으나 기계학습 컨트롤러의 위치에 따른 망 지연을 고려하지 않고 특정 상황에서의 성능개선을 목표로 하는 한계점이 있었다. ITU에서 제안한 기계학습용 논리적 망구조는 이런 한계를 극복할 수 있는 유용한 플랫폼 구조로 활용될 수 있다. 이 구조의 장점은 기계학습 컨트롤러의 위치에 따른 지연을 고려하여 기계학습 알고리즘을 선택적으로 사용할 수 있고 실시간 데이터와 오프라인 데이터를 병행 또는 선택적으로 사용할 수 있기 때문에 망 환경 변화에 맞춰 최적의 결과를 얻을 수 있다. 그러나 기계학습 모델 변경이 너무 빈번할 경우 망 전체 성능에 악영향을 미칠 수 있으므로 기계학습 알고리즘 변경주기에 대한 추가 연구가 필요하다.

V. 참고문헌

- [1] E. Chai, K. Sundaresan, M. A. Khojastepour, and R. Sampath, "LTE in Unlicensed Spectrum: Are We There Yet?" in Proc. of 22nd ACM International Conference on Mobile Computing and Networking (MobiCom 2016), New York City, NY: ACM, Oct. 2016, pp. 135–148.
- [2] F. M. Abinader, E. P. L. Almeida, F. S. Chaves, A. M. Cavalcante, R. D. Vieira, R. C. D. Paiva, A. M. Sobrinho, S. Choudhury, E. Tuomaala, K. Doppler, and V. A. Sousa, "Enabling the Coexistence of LTE and Wi-Fi in Unlicensed Bands," IEEE Communications Magazine (COMMAG), Vol. 52, No. 11, pp. 54–61, Nov. 2014.
- [3] G. Gür, "Expansive networks: Exploiting spectrum sharing for capacity boost and 6G vision," Journal of Communications and Networks, Vol. 22, No. 6, pp. 444–454, Dec. 2020.
- [4] I. Goodfellow, Y. Bengio, and A. Courville, Deep Learning. MIT Press, 2016, <http://www.deeplearningbook.org>.
- [5] R. S. Sutton and A. G. Barto, Reinforcement Learning, second. A Bradford Book, 2018.
- [6] S. Szott, K. Kosek-Szott, P. Gawłowicz, J. Torres Gómez, B. Bellalta, A. Zubow and F. Dressler, "Wi-Fi Meets ML: A Survey on Improving IEEE 802.11 Performance with Machine Learning," IEEE Communications Surveys & Tutorials, 2022. (online first)
- [7] S. Zinno, G. D. Stasi, S. Avallone, and G. Ventre, "On a fair coexistence of LTE and Wi-Fi in the unlicensed spectrum: A Survey," Elsevier Computer Communications, vol. 115, pp. 35–50, 2018.

- [8] P. Tian, "Traffic-Aware Resource Allocation and Spectrum Share for LTE-U and Wi-fi," in International Conference on Mechatronics and Intelligent Robotics, Springer, 2019, pp. 837–843.
- [9] H. Kushwaha, V. J. Kotagi, and C. S. R. Murthy, "A Novel Reinforcement Learning Based Adaptive Optimization of LTE-TDD Configurations for LTE-U/WiFi Coexistence," in 2019 IEEE 30th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC), IEEE, 2019, pp. 1–7.
- [10] K. Naveen and C. Amballa, "Coexistence of LTE-Unlicensed and WiFi: A Reinforcement Learning Framework," in 2021 International Conference on COMmunication Systems & NETworkS (COMSNETS), IEEE, 2021, pp. 308–316.
- [11] K. Zhou, A. Li, C. Dong, L. Zhang, and J. Sun, "LWCQ: An Adaptive Algorithm for LAA and WiFi Coexistence Based on Q-learning," in 2019 IEEE 19th International Conference on Communication Technology (ICCT), IEEE, 2019, pp. 556–560.
- [12] L. Wang, M. Zeng, J. Guo, Q. Cui, and Z. Fei, "Joint Bandwidth and Transmission Opportunity Allocation for the Coexistence Between NR-U and WiFi Systems in the Unlicensed Band," IEEE Transactions on Vehicular Technology, vol. 70, no. 11, pp. 11 881–11 893, 2021.
- [13] K. Kosek-Szott, A. Lo Valvo, S. Szott, P. Gallo, and I. Tinnirello, "Downlink channel access performance of NR-U: Impact of numerology and mini-slots on coexistence with Wi-Fi in the 5 GHz band," Computer Networks, vol. 195, p. 108 188, 2021.
- [14] I. Tinnirello, A. Lo Valvo, S. Szott, and K. Kosek-Szott, "No Reservations Required: Achieving Fairness between Wi-Fi and NR-U with Self-Deferral Only," in Proceedings of the 24th International ACM Conference on Modeling, Analysis and Simulation of Wireless and Mobile Systems, 2021, pp. 115–124.
- [15] A. Galanopoulos, F. Foukalas, and T. A. Tsiftsis, "Efficient coexistence of LTE with WiFi in the licensed and unlicensed spectrum aggregation," IEEE Transactions on Cognitive Communications and Networking, vol. 2, no. 2, pp. 129–140, 2016.
- [16] M. Girmay, A. Shahid, V. Maglogiannis, D. Naudts, and I. Moerman, "Machine Learning Enabled Wi-Fi Saturation Sensing for Fair Coexistence in Unlicensed Spectrum," IEEE Access, vol. 9, pp. 42959–42974, 2021.
- [17] A. M. Alenezi and K. A. Hamdi, "Reinforcement Learning Approach for Hybrid WiFi-VLC Networks," in 2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring), IEEE, 2020, pp. 1–5.
- [18] ITU-T, "Architectural framework for machine learning in future networks including IMT-2020," Recommendation ITU-T Y.3172, 2019.

저자소개



강영명 (Young-myung Kang)

2013 년 2 월 서울대학교 컴퓨터공학과 (공학박사)

2012 년 9 월 ~ 2021 년 3 월 삼성전자

2021 년 3 월 성결대학교 컴퓨터공학과 조교수

관심분야 : 인공지능, 네트워크, Wi-Fi, Optimization