

머신러닝 기반 무선 간섭관리 기술 동향

□ 하노검, 안지혜, 신원재 / 부산대학교

요약

4차 산업혁명 시대에는 무선 연결 기기 수의 급격한 증가와 무선 데이터 량의 폭발적 증대로 인해 무선 간섭관리의 중요성이 더욱 강조되고 있다. 본 고에서는 무선통신에서 간섭관리의 중요성과 기존 기법들의 한계점에 대해 알아보고, 최신 머신러닝 및 딥러닝 기술을 기반으로 간섭관리 문제를 해결하는 시도들에 대해 상세하게 소개한다.

I. 서론

인터넷은 현대 사회에 살고 있는 모두에게 필수 불가결한 요소가 되었다. 전 세계가 사용할 연간 IP 트래픽은 2021년에 10^{15} MB까지 도달할 것이라고 예측된다[1]. 이와 같은 IP 트래픽의 급격한 증가는 무선 통신을 필요로 하는 사물인터넷(Internet of

things, IoT)의 발전에 큰 영향을 받았다. 현재 사물인터넷 디바이스를 연결한 네트워크는 약 1억개를 형성하고 있고, 제4차 산업혁명의 시대가 도래함에 따라 2025년까지 약 250억개에 도달할 것이라고 예상된다[2]. 이와 같이 대규모 네트워크를 형성하는 무선 연결기기 혹은 이동 단말들을 효율적으로 관리하기 위해서는 새로운 통신 방식을 파악하고 개발해 나가야 할 것이다.

최근 상용화된 5세대 이동통신은 넓은 대역폭(Bandwidth)의 확보로 인해 기존 4세대 이동통신 네트워크가 지원할 수 있는 전송량의 10배 넘게 처리 가능한 수준이므로 늘어난 무선 연결기기를 지원할 수 있을 것이라 예상하고 있다. 하지만 다양한 네트워크 및 서비스가 혼재하고 무선기기의 수가 더욱 폭발적으로 증가하는 5세대 이후의 네트워

※ 이 성과는 2019년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. NRF-2019R1C1C1006806).

크 상황을 예상해 보면, 전자기파를 이용하는 무선 통신의 특성상 인접한 수많은 기기들간에 간섭 현상(interference)이 발생하고 이 때문에 네트워크 전송량 감소로 이어지는 문제가 나타날 것을 알 수 있다. 이러한 근본적인 문제를 해결하기 위하여 간섭의 영향을 조절하여 무선 네트워크가 달성할 수 있는 데이터 전송량을 증가시키는 다양한 간섭관리(Interference management) 기법들이 학계 및 산업체에서 많은 관심을 받고 있다.

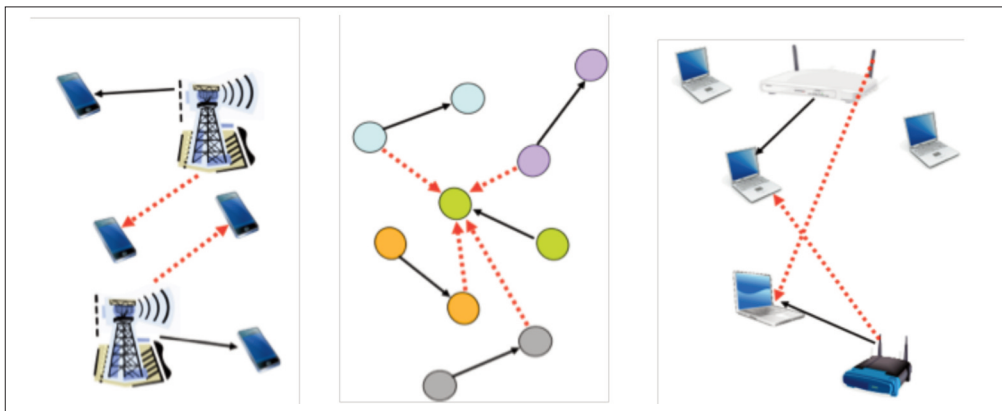
머신러닝은 경험적 자료들을 사용하여 알고리즘의 성능을 향상시키는 연산 방법으로 복잡한 자료들에 대한 분류 및 추정을 해결해내는 효과적인 기법이다. 이처럼 머신러닝은 임의의 정보에 대해서 우수한 자료 처리능력을 지니고 있어 여러 분야의 다양한 주제와 연결되고 있다. 그리고 현대의 빅데이터 기반 자료를 관리하기 위해서 딥러닝 역시 활발히 연구되고 있다. 딥러닝은 심층 신경망(Deep neural network)이 비선형적 함수, 가중치(Weight) 그리고 편향치(Bias)를 바탕으로 기존 알고리즘을 학습하는 방식이다. 딥러닝 기술은 기존 머신러닝과 비슷한 목적을 가지지만 몇 개의 층을

가진 심층 신경망으로 쉽게 학습할 수 있다는 특징이 있다. 낮은 학습 복잡도와 우수한 성능으로 인해 최근 다양한 분야에서 딥러닝을 적용하는 연구가 주목받고 있다. 통신 분야에서도 기존 통신 알고리즘과 최신 머신러닝 및 딥러닝 기술을 결합하려는 시도가 활발히 연구되고 있다.

본 고에서는 세가지 분류(지도학습, 비지도학습, 강화학습)의 머신러닝 및 딥러닝 기술의 특징을 간단하게 살펴보고, 각 기술들이 간섭관리 기법들과 어떻게 결합되어 연구되고 있는지 살펴볼 예정이다. 이후 세부 구성은 다음과 같다. II 장은 간섭관리가 왜 중요하고 이론적 한계점은 무엇인지에 대해 다룰 것이다. III 장에서는 머신러닝 및 딥러닝 기술이 간섭관리에 적용되는 최신 사례들을 세가지 분류로 나누어 상세하게 살펴볼 것이다. 마지막으로 IV 장을 통해 결론을 지으며 논문을 마무리할 것이다.

II. 간섭관리의 중요성 및 한계

1. 간섭관리의 중요성



(그림 1) 다양한 무선 네트워크에서의 간섭현상 (예: 셀룰러, 모바일 애드혹, 무선랜 시스템)

전자기파를 이용하는 무선통신의 특성상 근본적으로 서로 다른 신호들이 만나게 되면 중첩의 원리(Superposition principle)에 의해 서로 보강이 되거나 상쇄되는 간섭 현상이 발생한다. 이러한 간섭 현상으로 인해 어떠한 신호도 수신되지 않거나 송신기에서 보내지 않은 엉뚱한 신호가 수신되는 문제가 나타날 수 있다. 이러한 간섭 현상은 <그림 1>과 같이 다중 사용자의 신호가 혼재하는 셀룰러(Cellular) 네트워크, 모바일 애드혹(Ad-hoc) 네트워크, 무선랜(Wi-Fi) 시스템 등 다양한 환경에서 발생한다.

5세대 이동통신 시대가 도래함에 따라 따라 무선 연결 기기의 수가 폭발적으로 증가하였고, 간섭 문제가 더욱 중요해지고 있다. 일정 면적 내에 간섭원 수가 많아짐에 따라, 간섭 관리를 제대로 하지 않으면 통신 시스템 전체 성능 저하를 일으키는 요인이 되기 때문이다. 기존 통신 시스템에서도 이러한 심각한 간섭 문제를 해결하기 위한 다양한 방안들이 제시되어 왔다.

2. 기존 간섭관리 기법의 한계

현재 대부분 구현된 통신 시스템에서는 자원분할 기법으로 간섭회피(Interference avoidance) 기법을 사용한다. 즉, 간섭이 일어나게 될 현상을 미연에 방지하기 위해 시간, 주파수 등의 무선 자원을 분할하여 서로 다른 신호에 할당하는 방식이다. 시간을 나누어서 서로 다른 신호가 겹침이 없이 순차적으로 전송될 수 있도록 만들어 주는 방식을 시간 분할 방식(Time-Division Multiple Access, TDMA)이라고 부르고, 주파수를 나누어서 간섭을 회피하는 기법을 주파수 분할 방식(Frequency-Division Multiple Access, FDMA)라고 한다. 예를

들어, 4G LTE-A 시스템의 경우 coordinated scheduling을 통해 셀간 간섭을 회피하는 자원을 할당하는 기법들이 표준에 포함되어 있다[3].

하지만 이러한 cake-cutting 방식의 자원 분할 기법들을 사용할 경우, 근본적으로 간섭원 수가 증가할 때 단일 송/수신기가 보낼 수 있는 데이터 전송량이 지속적으로 줄어들 수밖에 없다는 이론적 한계점이 존재한다. 따라서 간섭원 수가 폭발적으로 증대되는 차세대 통신 네트워크 구조에는 적합하지 않은 방안이라고 볼 수 있다.

간섭회피 방안과 함께 실제 많은 통신 시스템에서 고려되는 주요 간섭관리 방법은 송신전력 제어(Transmit power control) 방법이다. 송신전력 제어를 통하여 인접 수신기에서 간섭의 영향을 거의 받지 않도록 전력 할당을 한다면, 결과적으로 서로 다른 송/수신기 간의 간섭(mutual interference) 영향을 줄일 수 있다. 하지만 송신전력을 줄이게 되면 원하는 신호 세기 자체가 줄어드는 부작용 현상이 발생함에 따라 간섭제어로 인해 네트워크 전체의 데이터 전송량이 오히려 줄어들 수도 있다[4]. 이러한 복잡한 송/수신기간 상호작용으로 인해 일반적인 간섭채널에서의 최적의 송신전력제어 해법은 잘 알려져 있지 않다.

마지막으로 간섭 신호의 세기가 수신하고자 하는 신호 대비 매우 큰 경우(Strong interference regime)에는 이론적으로 최적의 간섭관리 기법은 순차적 간섭제거 기법(Successive interference cancellation, SIC)이라고 알려져 있다[5]. 간섭의 세기가 매우 세기 때문에 간섭 신호를 먼저 복호화(Decoding)하고, 수신신호에서 해당 간섭 신호 성분을 완전히 제거해낸다. 간섭신호 성분을 완전히 제거한 이후에는 단일사용자 수신기(Single-user receiver)로 동작을 하면 되기 때문에 매우 좋은 성

능을 이론적으로 달성할 수 있다. 하지만 이러한 상황은 네트워크 구조 및 기지국 위치 등을 직접 설계하는 셀룰러 네트워크 환경에서는 거의 발생하지 않는다. 이는 인접 기지국(Adjacent BS)으로부터 오는 신호가 주 기지국(Serving BS) 신호보다 훨씬 센 경우가 있다면 이미 핸드오버(Handover)를 통해 주 기지국을 변경하게 스케줄러(Scheduler)가 동작할 것이기 때문이다. 따라서 순차적 간섭제거 기법의 경우 높은 성능을 보장하지만, 사용 가능한 무선 환경 자체가 많이 만들어지지 않는다는 근본적인 한계점이 존재한다.

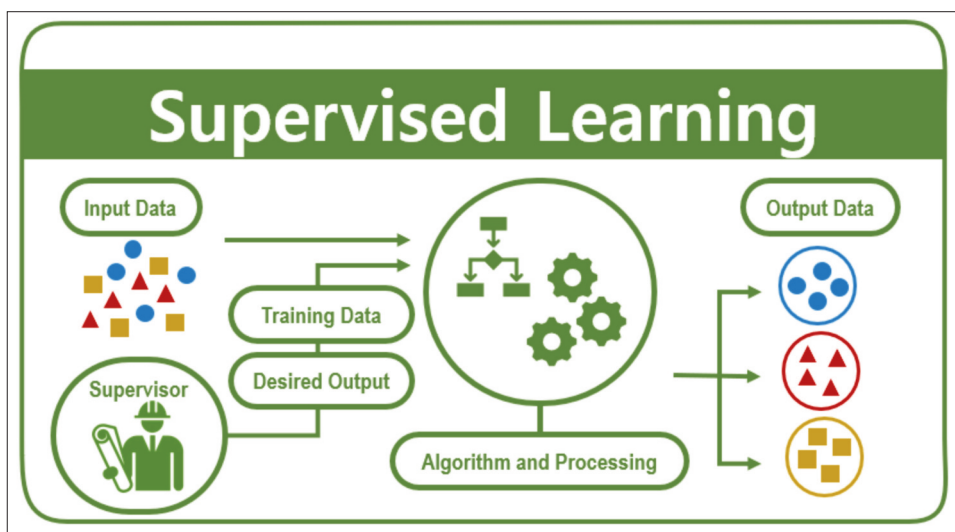
III. 머신러닝 기반 간섭관리

이번 장에서는 1. 지도학습, 2. 비지도학습 그리고 3. 강화학습을 간략하게 설명하고, 각 머신러닝 기법들이 최근 간섭관리 분야에 어떻게 적용이 되었는지 소개한다. 특히 이전 알고리즘들이 가지고 있던

문제점들의 해결 방식을 위주로 설명하며 머신러닝의 중요성을 짚어볼 것이다. 그리고 머신러닝이 아직까지 해결하지 못한 문제들을 논의하려고 한다.

1. 지도학습 기반 간섭관리 기법

기계에게 모든 답을 내려주도록 하는 “감독관”이나 “선생”을 두는 방법을 통해 기계를 학습시키는 방법을 지도학습이라고 부른다(〈그림 2〉 참조). 지도학습은 사용 목적에 따라 회귀(Regression)와 분류(Classification)의 크게 두 가지 종류로 나누어 볼 수 있다. 회귀는 학습된 데이터를 통해 주어진 입력에 대한 출력을 예측하는 방식이다. 회귀에서 쓰이는 기법은 선형 회귀(Linear regression), SVR(Support Vector Regression), 신경망(Neural networks) 등이 있다. 분류는 입력 정보들에 대해서 특징을 기준으로 범주를 나누는 방식이다. 통상 분류의 구체적인 기법으로는 SVM(Support Vector Machines), Naive Bayes, K-NN(K-Nearest Neighbor), 신경망 등의



〈그림 2〉 지도학습(Supervised learning) 흐름도

지도학습 알고리즘 등이 있다.

5세대 이동통신의 핵심요소기술 중 하나인 Massive MIMO(Massive Multi-Input Multi-Output)를 구현하기 위해서는 수십 개에서 수백 개 까지의 안테나들을 사용해야 한다. 이런 통신 상황에서 탐지(Detection)와 채널 추정(Channel estimation)을 하기 위해 알고리즘들은 엄청난 수의 신호 및 채널을 고려하여 무수히 많은 경우에 대해서 조사하고 계산해야 한다. 기존에 이러한 채널 환경에 대한 최적해(Optimal solution)을 구하는 방법이 이미 많은 연구가 되어있다. 하지만 massive MIMO을 위한 기존 알고리즘들은 최적해를 구하기 위해 많은 연산이 요구된다. 지도학습 알고리즘은 특정한 유형의 문제들과 답안들을 통해 가장 높은 점수를 얻도록 학습한다. 학습 후에 문제를 훌륭하게 풀어내는 알고리즘 및 변수들을 선정하면 비슷한 유형의 새로운 문제일 경우에도 빠르게 해결할 수 있다. 따라서 지도학습 기반 탐지 및 채널 추정을 통해 해를 얻기까지 걸리는 시간이 기존 탐지 및 채널 추정 알고리즘보다 매우 짧다. 지도학습은 저복잡도와 저지연을 요구하는 massive MIMO의 탐지 및 추정에 많이 적용되고 있다. 이번 장은 간섭관리에서 적용된 모델 기반 신경망 근사 지도학습 및 심층 합성곱 신경망(Convolution deep Neural Network, CNN) 기반 지도학습의 예시를 짚어보고 효과적인 결과들을 도출해내는 과정을 알아볼 것이다.

1) 모델 기반 신경망 근사를 통한 저복잡도 빔포밍 알고리즘 설계 기법

대부분의 간섭 네트워크에서 무선 자원 및 빔포밍 최적화 문제들은 non-convex 및 NP-hard 문제[7]로써 최적해를 구하는 과정이 매우 복잡하여

최적 결과를 얻어내기가 불가능했다. 그러므로 간섭관리를 위해서 앞선 연구들은 다양한 기법들, 예를 들자면 문제의 이중성(Duality)[8]이나 반복적인 알고리즘(Iterative algorithm)[9]을 이용하여 문제를 풀어내어 최적에 가까운 답을 찾는 것에 목표를 두었다. 이러한 알고리즘들 중 하나인 WMMSE(Weighted Minimum Mean Squared Error)[11]를 예시로 살펴보도록 한다. 논문 [11]의 주된 목적은 가중합-전송률을 최대화할 수 있는 빔포밍을 형성하는 것이다. 이 문제는 대표적인 non-convex 문제이므로 쉽게 최적해를 찾기 어렵다고 알려져 있다. 이 때문에 위의 문제를 풀어낼 수 있는 문제로 치환하기 위해 두 가지 수학적 개념이 필요하다. 첫째로 평균 제곱 오차(Mean Squared Error, MSE)를 최소화하는 문제는 convex 문제이므로 해결 가능하다는 것이고, 둘째로 MMSE (Minimize Mean Squared Error) 문제와 총합-전송률(Sum-rate) 최대화(Maximize) 문제의 답이 서로 치환 가능하다는 것이다. 따라서 송신된 신호와 수신된 신호 간의 차이(MSE)가 가장 작아지도록 만드는 수신기/송신기의 빔포밍(Beamforming)을 구하면 두 문제 간의 이중성(Duality)을 통해 가중합-전송률을 최대화하는 빔포밍을 형성할 수 있다. WMMSE는 다양한 통신 네트워크에서 가중합-전송률에 대한 최적해에 가까운 성능을 보여주기 때문에 많은 논문에서 언급되고 있다. 또한 현재 많은 지도학습 기반 간섭관리 기법도 WMMSE를 바탕으로 연구되고 있다.

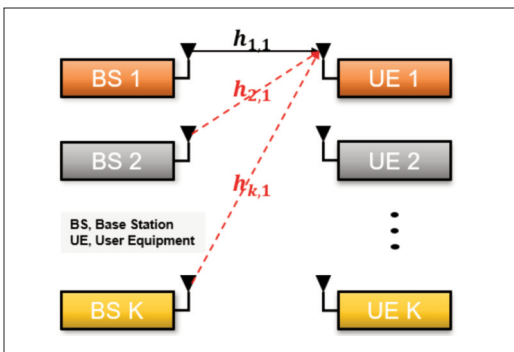
WMMSE 등의 반복 알고리즘들은 단순한 네트워크 구조(Network topology)에서 비교적 낮은 복잡도로 좋은 성능을 달성할 수 있다. 다만, 통신 네트워크가 복잡해질수록 반복 알고리즘들의 계산 과정도 더욱 복잡해진다. 그러므로 기존 방식으로 얻어

진 이론적인 분석 및 설계를 현실적 모델에 적용한다면 사용자와 기지국 간 정보 전달에 있어 지연(latency)이 발생한다. 종단간 지연(End-to-end latency)을 1 ms 이내로 맞추어야 하는 5세대 이동통신의 특성상 복잡한 알고리즘 연산에 의한 지연은 매우 치명적이다. 시간 지연 문제를 해결하기 위해 논문 [10]은 반복 알고리즘을 FCNN(Fully Connected Neural Network)에 근사하여 실시간 처리가 가능한 모델을 이끌어냈다. WMMSE에 근사한 심층 신경망은 기존 WMMSE 방법의 처리 속도 측면에서 더욱 효과적인 성능을 보였다.

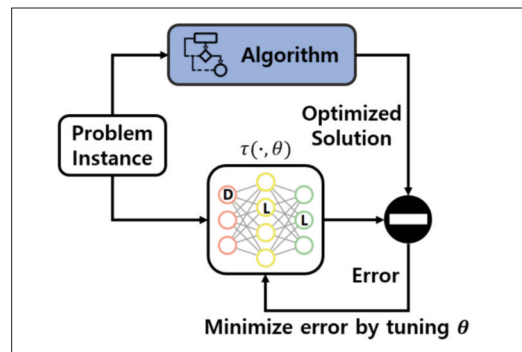
논문 [10]은 모든 반복 알고리즘들에 대해 심층 신경망으로 근사할 수 있음을 수식적으로 증명하며 시작한다. 이 증명은 학습이 가능한지 유무가 불분명한 상태에서 심층 신경망을 학습시키는 것이 아닌 어느 반복 알고리즘이더라도 심층 신경망에 학습시킬 수 있다는 것을 알려준다. 다음으로 위 증명을 통신 네트워크에 적용해보며 심층 신경망이 WMMSE를 학습하는 과정을 보여주고 성능을 기존 WMMSE와 비교한다. 시스템 모델은 K 명의 사용자와 기지국이 단일 안테나로 구성된 상황으로 고려하고 있다(〈그림 3〉 참조). 시스템 모델의 상황은

다른 기지국이 각자의 사용자에게 보내는 신호가 기지국 1이 사용자 1에게 신호를 보낼 때 간섭으로 작용하여 사용자 1이 바람직한 신호를 받기 어려워지는 상황이다. 시스템 모델을 바탕으로 WMMSE 알고리즘을 심층 신경망에 근사하는 과정은 다음과 같다. 첫번째로 위의 시스템 모델(System model)에 대한 채널 상태 정보(Channel state information)와 기존 WMMSE가 구해낸 정답을 바탕으로 심층 신경망의 가중치와 편향치를 학습시킨다. 두번째로 학습된 모델에서 나온 출력과 실제 WMMSE의 해당간의 오차를 감소시키는 방향으로 다시 가중치와 편향치를 학습시킨다. 이 알고리즘을 반복적으로 수행하여 WMMSE를 가장 잘 학습한 심층 신경망에 대한 최적 모델을 선정할 수 있다(〈그림 3〉 참조).

심층 신경망이 반복 알고리즘을 학습하여 기존 알고리즘의 복잡도를 완화한 부분이 획기적이며 복잡한 통신 네트워크이더라도 실시간 처리가 가능한 부분에서 논문 [10]은 기존 간섭관리 기법들에 비해 훌륭한 해결책이라고 볼 수 있다. 아쉽게도 논문 [10]의 기법은 기존 WMMSE가 풀어낸 정답을 통해 심층 신경망을 학습시킨 알고리즘이므로 이로부터 획득한 성능은 기존 WMMSE의 성능과 유의미한



〈그림 3〉 K 명의 사용자 간섭 채널 모델



〈그림 4〉 반복 알고리즘 근사화 흐름도

차이를 보이지 않았다.

2) 심층 합성곱 신경망 기반 빔포밍 설계 기법

앞서 살펴본 WMMSE 근사화 기반 심층신경망의 간섭관리 성능은 기존 WMMSE의 성능을 넘어서기 어렵다. 따라서 기존 방식을 심층 신경망이 학습하여 획득 가능한 성능이 아닌 간섭 관리에 대한 더욱 좋은 성능을 이끌어 내기 위해 다른 방식으로 접근할 필요가 있다.

논문 [12]를 통해 위의 문제를 어떻게 극복했는지 알아볼 수 있다. 먼저, 주어진 채널 행렬(Channel matrix)을 시험 문제로 두고 그에 대해 손실함수(Loss function)(수식 (3)과 수식 (4))를 정답지로 구성한다. 여기서 캐패시티(Capacity)란 신뢰할 수 있는 데이터의 최대 전송량으로 정의된다.

$$\text{User capacity} = \log_2 \left(1 + \frac{\text{Desired signal power}}{\text{Noise power} + \text{Interference power}} \right) \quad (3)$$

$$\text{Loss function} = -\sum \text{User capacity} \quad (4)$$


그 다음 심층 합성곱 신경망은 제시된 문제에 대해 손실함수가 가장 작을 수 있도록 정답을 고치도록 학습하는 과정을 거친다. 첫째로 심층 합성곱 신

경망은 각 합성곱 층(Convolution layer)의 주어진 첫번째 문제지와 정답지에 대해 가중치와 편향치를 학습한다. 이후 두번째, 세번째, 계속된 문제지와 정답지를 보고 잘못 학습된 가중치와 편향치는 0으로 만들고 잘 학습된 가중치와 편향치를 키워 나가도록 학습한다. 결과적으로 가장 정답지에 알맞도록 신경망을 학습시킨다. 이를 통해 기존 WMMSE와 WMMSE를 학습한 심층 신경망의 성능을 뛰어넘는 심층 합성곱 신경망을 획득할 수 있다.

이와 같은 방식으로 모델 기반 신경망 학습 알고리즘[10]에서 얻을 수 없었던 보다 우수한 성능을 획득할 수 있다. 하지만 학습을 이루는 구조에 대한 구체적인 내용과 학습 결과로 나온 각 층들의 값을 직관적으로 설명할 수 없어 학문적인 의미를 얻을 수 없다는 한계점이 존재한다.

3) 요약 및 시사점

앞서 살펴본 논문들은 기존 간섭관리 방식들로 구해진 값을 답지처럼 만들어 심층 신경망이 학습하도록 지도학습을 간섭관리에 적용하였다. 이와 같은 방식들은 전반적으로 기존의 알고리즘이 가진 복잡도를 낮출 수 있었다. 또한 가장 우수한 성능을



(그림 5) 주어진 채널 행렬과 손실함수의 학습을 위한 심층 합성곱 신경망[12]

보이는 모델이 구해지면 들어오는 입력에 따라 실시간으로 간섭관리가 가능하다. 그러나 지도학습은 환경이 바뀌면 대량의 자료를 통해 알고리즘을 다시 학습해야 된다는 점과 거대한 통신 상황의 경우 학습할 자료의 양이 방대하여 잘 학습된 알고리즘을 선정할 때까지 걸리는 시간이 매우 오래 걸리는 약점도 존재한다.

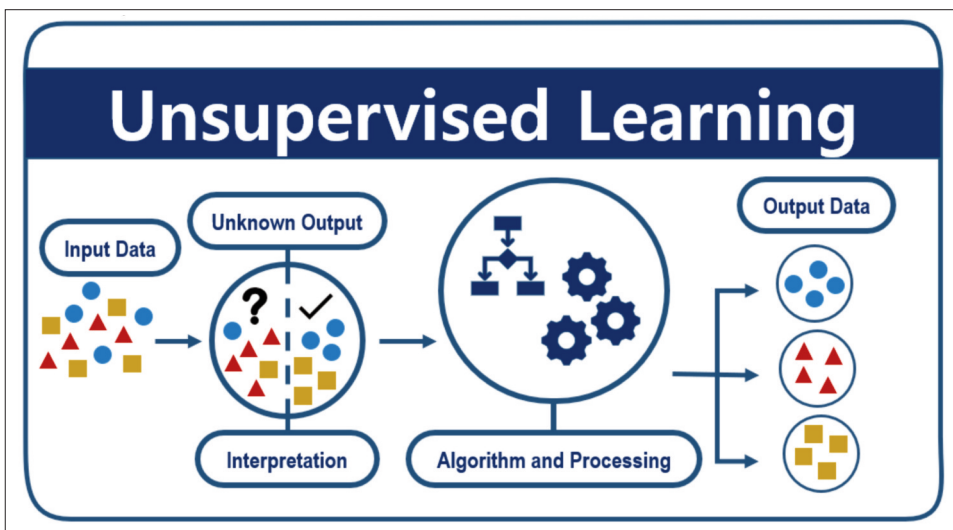
2. 비지도학습 기반 간섭관리 기법

비지도학습은 지도학습과 다르게 데이터에 대한 레이블(Label) 즉, 명시적인 정답이 주어지지 않은 데이터를 이용하여 학습을 하는 방식이다 (<그림 6> 참조). 데이터의 특징이나 관계를 파악할 수 있어 주로 데이터 이해를 위한 분석 단계에 사용된다. 비지도학습의 예시로는 비슷한 성질을 가지고 있는 데이터를 그룹화시키는 군집화(Clustering), 데이터의 차원을 줄이는 차원 축소(Dimension reduction), 출력이 입력과 같은 값이 나오도록 신

경망을 학습시키는 오토인코더(Autoencoder)가 존재한다. 이 절에서는 이러한 방법을 간섭관리에 적용한 사례를 소개한다.

1) D2D 통신 시스템에 적용된 군집화 알고리즘

군집화는 주어진 데이터들을 통해 비슷한 개체들을 하나의 그룹으로 묶는 것이 목적이다. 대표적인 알고리즘의 종류는 크게 가우시안 혼합 모델, 계층적 군집화, K -평균 군집화가 있다. 첫째로, 가우시안 혼합 모델(Gaussian Mixture Model, GMM)은 여러 개의 가우시안 분포(Gaussian distribution)를 선형 결합하여 만들어진 분포를 이용한 군집화 알고리즘이다. K 개의 가우시안 분포를 혼합하였을 때 주어진 데이터가 가장 높은 확률로 포함될 분포 $k \in K$ 를 선택함으로써 군집화를 한다. 둘째로 계층적(Hierarchical) 군집화는 객체 사이의 거리를 미리 계산한 자료를 통해 가장 가까운 거리에 존재하는 객체들을 결합하여 군집을 만들어 계층 구조를 형성해가는 방식이다.



<그림 6> 비지도학습(Unsupervised learning) 흐름도

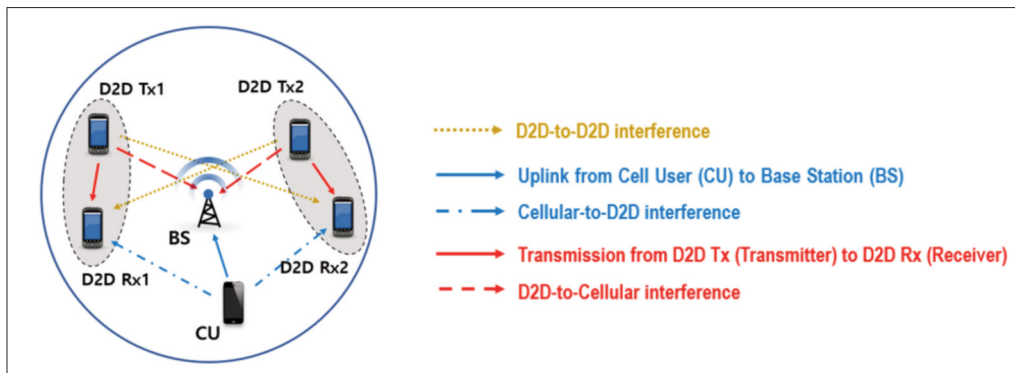
마지막으로 K -평균(K -means) 군집화는 전체 집합의 데이터를 K 개의 군집으로 분배하기 위한 알고리즘으로 각 클러스터와 거리 차이의 분산을 최소화하는 방식이다. K -평균 군집화의 세부 알고리즘은 다음과 같다. 먼저, K 개만큼 군집의 중심을 전체 집합의 데이터에서 무작위로 정한다. 그 다음 이러한 K 개의 중심들과 가까운 전체 집합의 원소들을 모아 전체 집합을 나누어 K 개의 군집을 만든다. 이때 각 군집의 중심들은 각 군집 내 점의 평균값으로 다시 계산하고 중심과 가까운 점들로 다시 K 개의 집합을 형성한다. 이런 과정을 반복적으로 수행하면 결국 각 군집의 중심들이 바뀌지 않는 상태가 되고 알고리즘을 더 이상 반복하지 않게 된다.

아래에서는 K -평균 군집화를 D2D 통신 시스템에 적용하여 간섭문제를 처리한 사례에 대해서 알아보려고 한다. 기존의 D2D(Device-to-device) 기술의 경우 셀 내의 기존 사용자와 같은 채널 자원을 사용하므로 <그림 7>과 같은 여러 간섭이 발생해 간섭 문제를 초래한다는 문제점이 수반된다. 이러한 간섭 문제는 무선 단말의 수가 증가할수록, 무선 단말 간의 거리가 가까워질수록 심화된다. 그래서 논문 [13]에서는 이러한 간섭 문제를 K -평균 군

집화를 통해 해결하고 있다.

충분히 거리가 멀어 서로 간의 간섭이 무시될 수 있을 정도인 D2D쌍들을 하나의 군집으로 만들고, 같은 군집안에 할당된 D2D쌍들에게 동일한 셀 사용자의 주파수 자원을 할당할 경우 간섭을 발생시키지 않으면서 자원을 재사용(Frequency reuse)할 수 있다. 따라서 주어진 자원을 효율적으로 사용하기 위해서 서로 간의 간섭이 적은 무선 단말들을 하나의 집합으로 군집화하여 자원을 할당하고 이를 통해 간섭을 줄이는 것이 필요하다. 이러한 이유로 이 논문 [13]에서는 간섭 강도(Interference intensity)와 반비례하는 거리 정보를 이용한 K -평균 군집화를 통해 D2D쌍들을 군집화하였다. 그리고 이를 통해 군집화된 D2D가 요구된 QoS(Quality of Service)를 만족하며 시스템의 전송량을 최대화하는 자원할당 알고리즘을 제시하였다.

제시된 군집화 방법을 통해 스케줄링을 할 경우 서로에게 많은 간섭 영향을 끼치는 D2D쌍들은 낮은 확률로 같은 군집에 할당된다는 특징을 가진다. 이렇게 K -평균 군집화 알고리즘을 통하여 자원을 할당할 경우 크게 작용했던 D2D쌍간의 간섭을 없앨 수 있으므로 적절한 자원 분배를 통해 간섭을 줄



<그림 7> 단일 셀 D2D 시스템의 업링크(Uplink) 상황에서 간섭 작용

임과 동시에 요구되는 성능을 얻을 수 있다.

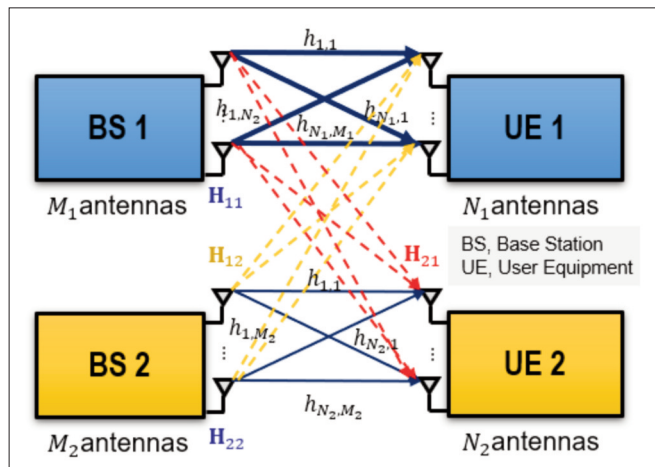
2) 차원 축소를 통한 채널 피드백 (Feedback) 부담 완화

차원 축소는 주어진 데이터의 차원을 축소하는 방식으로 정보를 잃는다는 단점과 동시에 크게 세 가지 장점이 존재하는 머신러닝 기법이다. 첫째, 데이터 압축(Compressing data)을 할 경우 시간과 저장 공간을 효율적으로 사용할 수 있다. 둘째, 데이터의 차원이 과도하게 높을 경우 성능 열화가 발생하는 차원의 저주(Curse of dimensionality) 현상을 피할 수 있다. 마지막으로 특징 추출(Feature extraction)을 통해 결과에 적은 영향을 끼치는 데이터의 특징을 찾을 수 있는 장점이 있다.

〈그림 8〉은 2개의 다중 안테나 송/수신기가 있을 때의 채널 환경을 나타내는 그림이다. 이와 같이 간섭이 존재하는 환경에서의 전체 채널 행렬은 $H_{global} = [H_{11} \ H_{12} \ \dots]$ 으로 나타내어진다. 이때 송신기에서 성능의 최적화와 주어진 자원의 효율적 사용을 위해 송신기와 수신기 사이의 채널 정보

(Channel State Information, CSI)가 요구되고 사용자의 채널 상태 정보를 기지국으로 피드백하는 것이 필요하다. 이때 간섭 채널 환경에서 많은 수의 송/수신기와 안테나가 존재할수록 H_{global} 의 차원이 높아지고 채널 상태 정보 피드백 오버헤드(Feedback overhead)는 증가한다. 이러한 점에서 채널 상태 정보를 압축하는 것은 대규모 간섭채널에서 다루어져야 할 문제 중 하나이다. 따라서 논문 [14]를 통해 피드백 오버헤드가 큰 massive MIMO 시스템에서 차원축소 기법을 채널 상태 정보 피드백에 적용한 사례를 소개한다.

기지국의 안테나 수가 증가할수록 요구되는 피드백 해야 하는 채널 정보량이 증가하기 때문에 massive MIMO 시스템의 피드백 오버헤드는 과도하게 증가하게 된다. 이를 해결하기 위해 논문 [6]에서 사용한 머신러닝 기법은 차원 축소 방식의 대표적인 방식인 PCA(Principal Component Analysis)를 채널 상태 정보 행렬에 적용하여 단말기에서 높은 차원의 채널 상태 정보 행렬이 낮은 차원으로 변환되도록 하였다.



〈그림 8〉 다중 안테나 기지국/사용자 간섭 채널 환경

PCA는 높은 차원의 채널 상태 정보 행렬의 공분산 행렬(Covariance matrix)의 고유값 분해(Eigenvalue decomposition)를 통해 얻어진 고유값을 통해 데이터를 선택한다. 이때 높은 고유값을 가지는 정보가 우선적으로 선택되는데 이렇게 정보를 보낼 경우 가장 중요하게 여겨지는 정보들은 전달되지만 일부는 제거된다는 문제점이 있다. 따라서 하나의 고유값이 전체 고유값 중 차지하는 비중을 나타내는 기여도(Contribution rate)라는 개념을 적용하여 선택된 정보들의 기여도의 합이 90%이상 일 경우의 정보 손실은 감수할 만하다고 판단하였다. 따라서 기여도의 합이 90%이상을 만족할 정도 만큼의 차원을 축소하여 채널 상태 정보를 보내도록 하였다. 이렇게 PCA를 통한 낮은 차원의 채널 상태 정보를 피드백함으로써 오버헤드를 낮추어 높은 오버헤드라는 문제점을 완화시킬 수 있다.

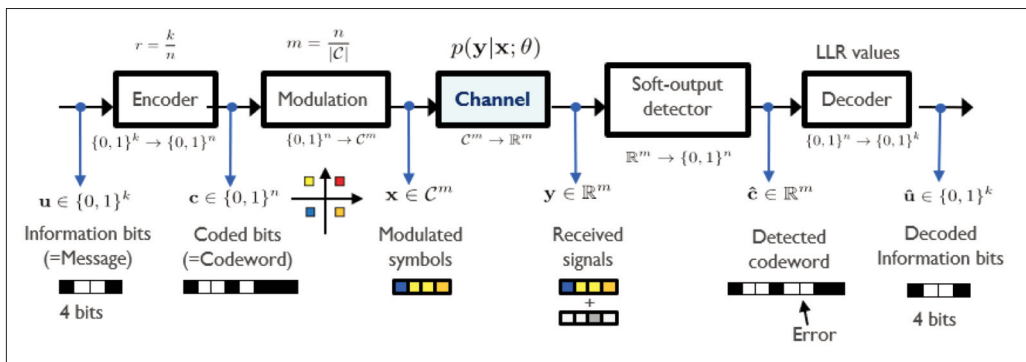
3) 저복잡도 통신 시스템을 위한 오토인코더

오토인코더는 손실함수가 $\|x - \hat{x}\|^2$ (x : 입력, \hat{x} : 출력)인 신경망으로 입력과 근사한 값의 출력 값이 나오도록 하는 기법이다. 이때 입력과 출력층의 노드의 개수는 동일하되 은닉 층(Hidden layer)의 노

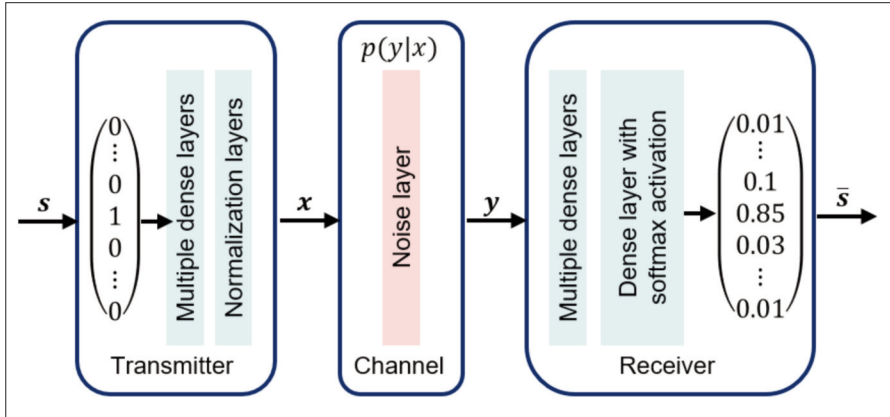
드는 입력과 출력의 노드 수보다 적다는 특징을 가진다. 이는 은닉 층의 노드 수가 입/출력과 동일할 경우 받은 입력을 그대로 출력해버리는 것을 막기 위함이다.

기본적인 통신 시스템 블록 다이어그램은 <그림 9>과 같이 나타내어진다. 이때 모든 단계를 한번에 최적화하는 것이 아니라 각각의 블록마다 성능을 최적화하므로 전체적인 결과가 최적해가 아닐 수 있다. 이러한 블록 다이어그램은 제안된 딥러닝 기반의 접근 방법을 통해서 end-to-end 최적화 문제로 재구성 할 수 있고 시스템은 <그림 10>과 같이 오토인코더 시스템으로 나타내어 질 수 있다. 이때 송신단과 수신단은 심층 신경망으로 표현되고 사이에 존재하는 부가 백색 가우스 잡음(Additive White Gaussian Noise, AWGN)채널은 간단한 노이즈 층(Noise layer)으로 표현된다. 따라서 통신 시스템은 입력 값을 통해 학습하는 것을 목적으로 하는 하나의 오토인코더로 여길 수 있다.

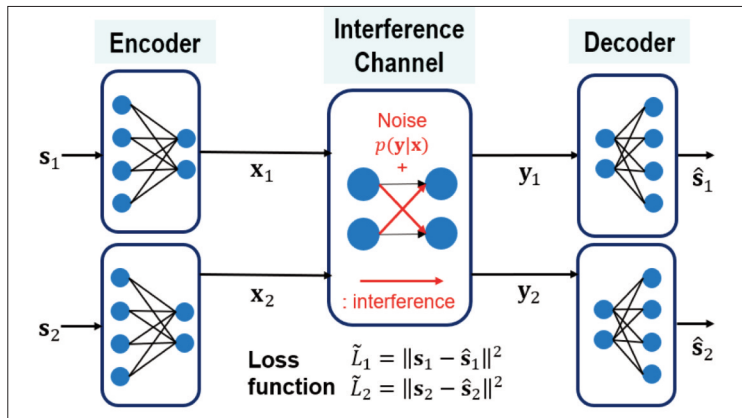
오토인코더 시스템에서는 M차원의 one-hot-vector인 입력 신호 s 가 송신부인 여러 층과 표준화 층(Normalization layer)을 지나 에너지 제한을 가진 N차원의 신호 x 로 전환되어 송신되고, 수신단에



<그림 9> 전통적인 통신 시스템 블록 다이어그램



〈그림 10〉 Autoencoder system



〈그림 11〉 두 명의 사용자가 존재할 때의 간섭 채널

서 N 차원의 신호 y 를 받아 여러 층과 마지막으로 Softmax activation 층을 통해 M 차원의 요소들의 합이 1인 확률 벡터를 구하여 이 중에서 가장 높은 확률을 가지는 요소를 선택하여 신호가 디코딩된다.

논문 [15]에서는 이와 같은 딥러닝 신경망 기반의 오토인코더 학습을 간섭채널에 적용하여 신호를 디코딩하는 알고리즘을 제안한다. 두 명의 사용자가 존재할 때 간섭 채널을 〈그림 11〉과 같이 나타내어 질 수 있고 신호 s_1, s_2 는 codeword에서 통해서 선택된다. 이때 K 개의 사용자가 있다고 했을 때 송신

된 신호는 $y_i = x_i + g \sum_{i \neq j} x_j + z_i \quad \forall i = 1, \dots, K$ 이다. $g > 0$ 은 간섭세기(Interference strength)를 나타내고 z_i 는 평균이 0이고 분산이 1인 가우시안 분포의 벡터를 의미한다. 논문 [15]에서는 여러가지 간섭 레벨을 가지는 채널상황에서 오토인코더를 적용하였고 간섭 레벨에 대한 정보를 이용하여 학습하였을 때 간섭채널에 대해 강한 성능을 가지는 것을 보였다. 하지만 구현을 통해 이러한 오토인코더의 학습에 있어서 간섭 레벨에 대한 정보가 큰 영향을 끼친다는 한계점 또한 확인할 수 있다.



〈그림 12〉 강화학습(Reinforcement learning) 흐름도

4) 요약 및 시사점

이 절에서는 비지도학습을 적용한 간섭 관리의 다양한 예를 살펴보았다. 이를 통해 비지도학습의 적용이 간섭 채널 상황에서의 성능 개선을 유도할 수 있을 뿐 만 아니라 자원할당과 같은 문제에 적용됨으로써 간섭 감쇄 또한 유도할 수 있음을 알 수 있었다. 이러한 학습은 모두 최적의 해가 주어지지 않은 상황에서 이루어지므로 비지도학습을 통한 간섭 관리는 최적의 해가 주어지지 않거나 구하기 어려운 경우에 효과적으로 작용할 것으로 기대된다.


3. 강화학습 기반 간섭관리 기법

강화학습은 심리학에서 많은 영감을 받아 만들어진 학습 방법론으로, 행동에 대한 보상을 바탕으로 가장 좋은 결과를 얻을 수 있는 행동을 선택하는 알고리즘이다(〈그림 12〉 참조). 이러한 바탕의 강화학습은 비지도학습 및 지도학습과 달리 뒤늦게 머신

러닝의 한 분류로 속하게 되었다.

강화학습 모델은 대리인(Agent)과 환경(Environment)으로 형성된다. 특정 보상(Reward)이나 효용성(Utility)에 따라 대리인이 행동하여 모델의 구성 환경이 바뀐다. 피드백 혹은 보상이 다시 대리인에게 피드백되고 이 영향이 다시금 대리인의 행동을 조정한다. 대리인은 최적의 행동을 할 때까지 이러한 과정을 반복한다. 결과적으로 학습된 대리인 혹은 대리인들(Multi-agent)로부터 목표했던 결과를 얻을 수 있는 알고리즘이다.

기본적인 강화학습인 Q-학습(Q-Learning)은 Q-테이블(Q-table)에 각 상태 변화와 행동에 따른 결과값을 저장하여 평균 보상이 가장 큰 경우를 결정하도록 행동하게 만드는 학습 알고리즘이다. 이후에 나온 심층 Q-네트워크(Deep Q-Network, DQN)[16]는 Capture and Replay와 Separate Network을 도입하여 Q-학습을 발전시켰다. 고전적인 Q-학습과 달리 심층 Q-네트워크는 학습 대



〈그림 13〉 시간 변화에 따른 최적 군집화를 위한 조합 문제

리인의 수에 제약이 없고 이산적 상태(Discrete state)를 사용하여 환경을 구축할 필요가 없다.

일반적으로 강화학습은 통신 분야에서 펌토/스몰 셀 채널 선택(Femto/small cell channel selection)의 자원 할당(Resource allocation), D2D 네트워크의 대역 공유(Spectrum sharing) 그리고 에너지 하베스팅(Energy harvesting) 등의 동적 변화에 대응할 수 있는 알고리즘으로 사용된다. 본 고에서는 그 중 Cooperative transmission 네트워크에서 군집화에 적용된 강화학습과 동적 자원 할당을 위한 강화학습을 살펴볼 것이다.

1) Cooperative transmission 네트워크에서 군집화를 위한 강화학습

5세대 통신 체계는 기존 통신 방식보다 높은 전송률(Rate)을 요구한다. 기존의 셀룰러 시스템의 셀보다 더 작은 영역을 관리하는 펌토/스몰 셀들을 배치하는 것은 전송률을 높이기 위한 효과적인 방법 중 한가지다. 하지만, 오히려 많은 스몰 셀들이 존재하는 경우 다른 스몰 셀들에서 오는 간섭

이 스몰 셀 내의 성능에 악영향을 미친다. 동적 군집화(Dynamic clustering) 알고리즘은 이러한 간섭 상황에 대해 최대 총합-전송률을 얻을 수 있도록 스몰 셀들의 군집을 만드는 알고리즘이다. 시간에 따라 어떤 통신 상황이 발생할지 모르기 때문에 무수히 많은 군집 경우를 고려해야 한다. 그러므로 동적 군집화를 위해 복잡한 조합 최적화 문제(Combinatorial optimization problem)를 풀어내야 하고 이는 아주 복잡한 계산을 요구한다(〈그림 13〉 참조). 논문 [17]은 알고리즘 연산의 복잡도를 낮추기 위한 해결책을 제시한다. 정해진 경우의 군집 방식 중에 가장 높은 총합-전송률을 획득할 수 있는 군집 방식을 고르는 준-동적 군집화(Semi-dynamic clustering) 방식과 Q-학습을 결합하여 논문 [17]은 계산에 걸리는 시간을 단축하며 동시에 동적 군집화 알고리즘의 성능에 가까운 결과를 이끌어낸다.

다음과 같이 각 사용자 간의 신호 간섭을 관리하기 위해 특별한 함수를 지정한다. 첫째로 각 군집에 해당하는 스몰 셀들과 사용자들 간 단일 안테나 모

델 중 K 셀의 k 번째 사용자에게 대한 캐패시티(수식 (5)) 를 목적 함수로 잡는다.

$$C_k = \log_2 \left(1 + \frac{\text{Desired signal power}}{\text{Interference power} + \text{Noise power in } K \text{ cluster}} \right) \quad (5)$$

둘째로 모든 스몰 셀 내의 사용자들에 대한 캐패시티의 총합이 이전보다 작아지면 상태가 0이 되고 아니라면 1이 되도록 각 시간 해당하는 상태(수식(6)) 는 다음과 같이 설정한다.

$$s_t = t \text{ time's state} = \begin{cases} 0, & \text{when outage occurs} \\ 1, & \text{otherwise} \end{cases} \quad (6)$$


이를 통해 상태가 0인 경우 대리인이 아무런 보상을 가지지 않고 상태가 1인 경우 대리인이 보상을 획득하도록 보상 함수를 설정한다.

결과적으로 대리인은 <그림 12>와 같이 전체 사용자에게 대한 캐패시티의 총합이 가장 큰 경우가 되도록 군집을 고르는 선택을 한다. 이 알고리즘을 통해 복잡한 상황에서도 빠른 계산을 통해 동적 군집화 알고리즘의 성능에 가까운 결과를 구해낼 수 있다. 하지만 논문 [17]은 준-동적 군집화를 통해 특정 군집의 경우만을 고려하여 정해진 상황에 알맞은 결과만 구해낼 수 있다. 이는 학습된 환경을 제외하고 다른 환경에 알고리즘을 적용할 수 없다는 문제가 발생한다. 따라서 향후 다양한 상황에 적용될 수 있도록 알고리즘을 개선할 필요가 있다.

2) 강화학습 기반 동적 자원 할당

송/수신 안테나, 사용자 수, 그리고 AP(Access Point)가 협소한 공간에 더욱 밀집되는 현재 무선환경에서 기존 WMMSE 등의 모델 기반 알고리즘은 최적해를 획득하기까지 상당한 시간을 요구한다. 그리고 동적으로 변화하는 네트워크 상황을 고려할 때 모델 기반 알고리즘은 다시 계산해야 하고 이는 추가적인 시간을 필요로 한다. 기존 지도학습이나

비지도학습의 경우, 지연된 정보 교환 등의 불완전한 채널 상태 정보 아래에서 본래 성능을 보여주지 못한다. 이렇듯 현재 복잡한 통신 상황들은 기존 방식으로 해결하기 어렵다. 이를 해결하기 위해서 심층 Q-네트워크를 이용한 간섭관리 알고리즘들이 나오고 있다[18]. 새로이 등장한 이 알고리즘들은 다양한 상황에서도 견고하며 모델에 제약이 없다는 특징을 가진다. 논문 [19] 역시 심층 Q-네트워크를 이용하여 불완전한 채널 상태 정보 아래서 최적의 자원 할당을 이끌어내는 알고리즘이다.



(그림 14) Central controller based backhaul network

각각의 AP가 신호를 주고받는 채널과 간섭을 유발하는 채널들에 대한 정보를 곧장 중앙의 Controller에게 보내는 것은 엄청난 부담이다. 따라서 여러 연구에서 백홀 네트워크(Backhaul network)는 AP와 Controller의 중간 연결망으로써 이러한 문제의 해결책으로 쓰인다(<그림 14>). 하지만 백홀 네트워크를 이용한 중심화 접근(Centralized approach)의 경우 정보를 전송하는 과정이 길어지므로 지연되거나 만료된 채널 정보만이 중앙의 Controller에게 전달된다. 논문 [19]는 이와 같은 접근으로 발생하는 지연 채널 정보만으로 대리인들 즉, 기지국들이 각자 전송률을 높일 수 있게 강화학습 기반 알고리즘을 설계하였다.

$$A = \left\{0, \frac{P}{|A|-1}, \frac{2P}{|A|-1}, \dots, P\right\}, P = \text{maximum transmit power} \quad (7)$$

먼저 대리인들은 다음과 같이 구성된 행동 집합 (수식 (7))에서 특정 행동을 취한다. 이렇게 정해진 행동에 따라 각 i 번째 사용자와 i 번째 기지국에 의해 간섭을 받는 사용자들의 가중합-전송률이 이전 단계보다 커진다면 각 대리인들은 이에 대한 보상을 얻을 수 있다. 대신에 정해진 행동이 가중합-전송률을 이전 단계보다 높이지 않는다면 각 대리인들은 보상을 받지 못한다. 다음 단계에서 주어지는 지연 채널 상태 정보와 이러한 보상을 피드백하여 다시금 대리인들은 행동을 수정한다. 이러한 과정을 반복적으로 시행하여 <그림 12>에 따라 최적 행동을 하도록 유도된다.

논문 [19]는 지연된 채널 정보만을 이용하여 자원 분배를 할 수 있음에도 이상적인 WMMSE의 경우보다 총합-전송률에서 우수한 성능을 보인다. 하지만 중심화 네트워크(Centralized network)를 통해 전체 채널 상태 정보(Full-CSI)를 알아야 한다는 점은 큰 오버헤드(Overhead)로써 차후에 개선할 점으로 여겨진다.

3) 요약 및 시사점

기존 머신러닝을 간섭관리에 적용할 때 크게 두 가지 약점이 있다. 첫째로 지도학습이나 비지도학습의 경우 학습된 상황 이외에는 대처하지 못한다

는 점이다. 둘째로 채널 상태 정보를 완전히 아는 경우에만 학습을 제대로 할 수 있다는 점이다. 이번 절에서 살펴본 강화학습은 이와 달리 대리인이 스스로 무수히 많은 행동 중 하나를 시도해보고 보상을 얻는 것에 실패한다면 다시 다른 행동을 취하여 최적 행동까지 이르는 학습 방식이다. 또한 논문 [19]에 나온 것과 같이 채널 상태 정보에 대한 영향에 견고하다. 이처럼 기존 머신러닝들보다 다양한 상황을 스스로 학습하는 강화학습은 기존 방식의 단점들을 해결할 수 있다는 점에서 중심적인 알고리즘이 될 가능성이 클 것이라 예상된다.

IV. 결론

본 고에서는 무선 간섭관리를 위해 최신 머신러닝 및 딥러닝 기술들을 적용한 사례들을 살펴보았다. 특히 지도학습, 비지도학습, 강화학습으로 나누어 간섭관리 응용 사례를 소개하였고, 각각의 기술의 장점 및 한계점에 대해 분석하였다. 향후 딥러닝 기술의 발전과 컴퓨팅 능력의 향상에 따라, 보다 혁신적인 머신러닝 기반 간섭관리 기술들이 지속적으로 개발되어 초연결 시대의 핵심기술로 자리매김하게 될 것이라 기대된다.

참고 문헌

- [1] Cisco Visual Networking Index: Forecast and Methodology, 2016-2021, Cisco, San Jose, CA, USA, Jun. 2017.
- [2] P. Cerwall et al., "The ericsson mobility report," Ericsson, Stockholm, Sweden, White Paper EAB-19:007381 Uen, Revision A, Nov. 2019

- [3] D. Lee, H. Seo, B. Clerckx, E. Hardouin, D. Mazzaresse, S. Nagata, and K. Sayana, "Coordinated multipoint transmission and reception in LTE-advanced: deployment scenarios and operational challenges," *IEEE Communications Magazine*, vol. 50, no. 2, pp. 148-155, Feb. 2012.
- [4] M. Chiang, P. Hande, T. Lan, and C. W. Tan, "Power control in wireless cellular networks," *Foundations and Trends in Network*, Apr. 2008.
- [5] H. Sato, "The capacity of the Gaussian interference channel under strong interference," *IEEE Transactions on Information Theory*, vol. 27, no. 6, pp. 786 - 788, Nov. 1981.
- [6] D. Schmidt, C. Shi, R. Berry, M. Honig, and W. Utschick, "Distributed resource allocation schemes," *IEEE Signal Processing Magazine*, vol. 26, no. 5, pp. 53-63, Sep. 2009.
- [7] Z. Q. Luo and S. Zhang, "Dynamic spectrum management: complexity and duality," *IEEE Journal of Selected Topics in Signal Processing*, vol. 2, no. 1, pp. 57-73, Feb. 2008.
- [8] S. S. Christensen, R. Argawal, E. de Carvalho, and J. M. Cioffi, "Weighted sum-rate maximization using weighted MMSE for MIMO-BC beamforming design," *IEEE Transactions on Wireless Communications*, vol. 7, no. 12, pp. 1-7, Dec. 2008.
- [9] K. Gomadam, V. Cadambe, and S. Jafar, "A distributed numerical approach to interference alignment and applications to wireless interference networks," *IEEE Transactions on Information Theory*, vol. 27, no. 6, pp. 3309-3322, Jun. 2011.
- [10] H. Sun, X. Chen, Q. Shi, M. Hong, X. Fu, and N. D. Sidiropoulos, "Learning to optimize training deep neural network for interference management," *IEEE Transactions on Signal Processing*, vol. 66, no. 20, pp. 5438-5453, Oct. 2018.
- [11] Q. Shi, M. Razaviyayn, Z. Q. Luo, and C. He, "An iteratively weighted MMSE approach to distributed sum-utility maximization for a MIMO interfering broadcast channel," *IEEE Transactions on Signal Process*, vol. 59, no. 9, pp. 4331-4340, Sep. 2011.
- [12] W. Lee, M. Kim, and D. H. Cho, "Deep power control: Transmit power control scheme based on convolutional neural network," *IEEE Communications Letters*, vol. 22, no. 6, pp. 1276-1279, Jun. 2018.
- [13] X. Huang, M. Zeng, J. Fan, X. Fan, and X. Tang, "A full duplex D2D clustering resource allocation scheme based on a K-Means algorithm," *Hindawi journal Wireless Communications and Mobile Computing*, vol. 2018, Article ID. 1843083, pp. 1-8, May 2018.
- [14] A. Ge, T. Zhang, Z. Hu, and Z. Zeng, "Principal component analysis based limited feedback scheme for massive MIMO systems," *IEEE 26th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC)*, Hong Kong, China, Sep. 2015.
- [15] D. Wu, M. Nekovee, and Y. Wang, "Deep learning based autoencoder for interference channel," *arXiv e-prints*, arXiv:1902.06841, Feb. 2019.
- [16] B. C. Chung and D. H. Cho, "Semi-dynamic cell-clustering algorithm based on reinforcement learning in cooperative transmission system," *IEEE Systems Journal*, vol. 12, no. 4, pp. 3853-3856, Dec. 2018.
- [17] V. Mnih et al., "Human-level control through deep reinforcement learning". In: *Nature* 518.7540, pp. 529-533, Feb. 2015.
- [18] K. N. Doan, M. Vaezi, W. Shin, H. V. Poor, H. Shin, and T. Q. S. Quek, "Power allocation in cache-aided NOMA systems: optimization and deep reinforcement learning approaches," *IEEE Transactions on Communications*, (Early access), Oct. 2019.
- [19] Y. S. Nasir and D. Guo, "Multi-agent deep reinforcement learning for dynamic power allocation in wireless networks," *IEEE Journal on Selected Areas in Communications*, vol. 37, no. 10, pp. 2239-2250, Oct. 2019.

필자 소개



하노겸

- 2019년 : 부산대학교 전자공학과 학사
- 2019년 ~ 현재 : 부산대학교 전자공학과 석박사통합과정
- 주관심분야 : 통신이론, 머신러닝 응용



안지혜

- 2019년 : 부산대학교 전자공학과 학사
- 2019년 ~ 현재 : 부산대학교 전자공학과 석사
- 주관심분야 : 통신이론, 최적화 이론



신원재

- 2007년 ~ 2013년 : 삼성전자 종합기술원 전문연구원
- 2013년 ~ 2014년 : 삼성전자 DMC연구소 책임연구원
- 2017년 : 서울대학교 전기정보공학부 박사
- 2017년 ~ 2018년 : 미국 Princeton University Postdoctoral Research Fellow
- 2018년 ~ 현재 : 부산대학교 전자공학과 조교수
- 주요관심분야 : 차세대 이동통신 시스템, 머신러닝 및 빅데이터 신호 처리