

AI 기반 이동통신 물리계층 기술 동향과 전망

Physical-Layer Technology Trend and Prospect for AI-based Mobile Communication

장갑석 (K. Chang, kschang@etri.re.kr)

6G무선방식연구실 책임연구원/기술총괄

고영조 (Y.J. Ko, koyj@etri.re.kr)

6G무선방식연구실 책임연구원/실장

김일규 (I.G. Kim, igkim@etri.re.kr)

미래이동통신연구본부 책임연구원/본부장

ABSTRACT

The 6G mobile communication system will become a backbone infrastructure around 2030 for the future digital world by providing distinctive services such as five-sense holograms, ultra-high reliability/low-latency, ultra-high-precision positioning, ultra-massive connectivity, and gigabit-per-second data rate for aerial and maritime terminals. The recent remarkable advances in machine learning (ML) technology have recognized its efficiency in wireless networking fields such as resource management and cell-configuration optimization. Further innovation in ML is expected to play an important role in solving new problems arising from 6G network management and service delivery. In contrast, an approach to apply ML to a physical-layer (PHY) target tackles the basic problems in radio links, such as overcoming signal distortion and interference. This paper reviews the methodologies of ML-based PHY, relevant industrial trends, and candidate technologies, including future research directions and standardization impacts.

KEYWORDS 6G, Machine Learning, Deep Learning, Mobile Physical-layer Learning

1. 서론

한국은 2019년 4월 세계 최초 5G 버티컬 서비스 개시 이후 2020년 이를 본격화하고 있다. 10년 단위의 세대 전환주기를 참작하면 2030년경 6G 이동통신 서비스 실현이 전망된다[1]. 6G 이동통신 시

스템은 초신뢰·초저지연 5감 홀로그램 통신과 같은 초성능, 기가급 실감 영상 공중·해상 통신과 같은 초공간, 10cm 오차 위치측위와 같은 초정밀, 인간 또는 기계와 기계 간 초연결 등의 서비스를 제공함으로써 새로운 디지털 세계의 백본 인프라가 될 것이다.

* DOI: <https://doi.org/10.22648/ETRI.2020.J.350502>

* 이 논문은 2020년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임[No. 2019-0-00002, (전문연구실) 초정밀 서비스 실현을 위한 On-Time·On-Rate 무선액세스 및 광에지 클라우드 네트워크 핵심기술 개발].



본 저작물은 공공누리 제4유형

출처표시+상업적이용금지+변경금지 조건에 따라 이용할 수 있습니다.

©2020 한국전자통신연구원

기존 이동통신에서는 수학적 수단 기반 전송 용량 증대 기법을 꾸준히 발전시켜 왔다. 앞으로 AI(Artificial Intelligence) 단말이 기하급수적으로 증가할 것이다. 이로 인해 단말 간 새로운 형태의 대용량·대규모 연결 서비스가 증가하면 기존 방법으로는 한정적 무선자원의 최적 활용이 어렵다. 또한, 이론적으로 최고성능 달성 방법이라도 구현 복잡도, 계산량 가중 및 시간 지연 등의 문제가 있다. 최근 이를 해결하고 최적 자원사용에 좋은 ML(Machine Learning)이 등장했으며, 그중 DL(Deep Learning)이 가장 관심도가 높다. 셀 무선자원관리와 셀구성 최적화 등의 무선 네트워킹 분야에 현 단계의 ML 기술이 응용되기 시작했다. 반면, 무선구간에서 생기는 다양한 신호 왜곡/간섭 현상을 극복하고, 5G 대비 초고속·초저복잡·초성능을 달성하기 위해 ML을 물리계층에 응용하려는 연구는 몇몇 해결해야 할 근본적 과제가 있다.

본 고에서는 ML 기반 물리계층 기술 개론, 산학연 기관 동향 및 후보 세부기술 동향과 함께, 연구 방향성 및 전망을 제시한다.

II. ML 기반 물리계층 기술 개론

일반적으로 이동통신은 입력신호(x)가 무선 채널(H)을 통과하고, 잡음(n)이 더해지는 수신 신호($y = Hx + n$)로 모델링된다. 이는 ML의 $y = f(x) + \epsilon$ 와 유사한 형태이며, ϵ 은 설명하지 못하는 잔차로서 n 에 해당된다. 또한 DL에서 오차를 최소화해 $\hat{f}(x)$ 를 얻는 방식은 통신에 널리 사용되는 MMSE(Minimum Mean Squared Error)를 적용한다. 통신시스템은 정보 데이터를 무선채널로 전송하기 위한 송신 세부기술 블록들과 이에 상응하는 수신 세부기술 블록으로 구성된다.

그림 1은 세부기술 블록 중 채널복호기를 DL로




그림 1 물리계층 세부기술 블록 대체 ML 응용 예

대체하는 예이다. 이러한 세부기술 블록의 ML 대체 경우는 다수 송수신기가 데이터를 교환하는 간섭채널 등에서 이론적 한계에 도달하는 최적 성능과 낮은 구현 복잡도를 달성하기 위해, 비직교 방식¹⁾의 통신시스템에 고려되고 있다. 컴퓨터를 통해 데이터를 구하기 때문에 원하는 만큼 학습데이터를 얻을 수 있으며, 오프라인 학습 단계에서는 긴 시간이 걸릴 수 있으나 실제 시스템에 적용하는 단계에서는 행렬 곱셈과 비선형 함수를 적용하는 단순한 연산이 반복되므로 구현 복잡도를 현저히 줄일 수 있는 장점이 있다.

그림 2는 세부기술 블록들로 구성되는 통신시스템을 종단 간 AE(Auto-Encoder)로 해석해 전체를 DL로 대체하는 예이다[2]. 이 경우는 통신시스템의 송수신 전체 세부블록을 통합해 하나의 DL net으로 오프라인 학습하기 때문에 시스템이 매우 단순해지는 장점이 있다. 그러나 기존 세부블록들이 담당하는 기능들을 모두 묘사해야 하므로 효과적 학습 방법을 찾기 어려운 단점 또한 지니고 있으므로 현재는 세부기술 블록 대체 연구가 주를 이룬다.

자연 또는 사회 현상 등의 경우, 최적 해를 정의하기도 쉽지 않고, 학습데이터를 얻기도 쉽지 않

1) 다수 송수신기가 자원을 공유해 송수신하는 방식으로, 이 방식의 경우, 현재 통신시스템에 적용하기에는 복잡도가 매우 높고 글로벌 해가 없는 non-convex 문제가 대부분을 차지한다.

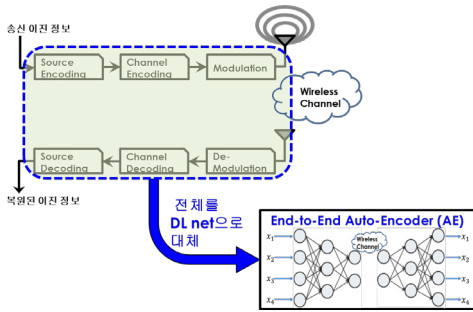


그림 2 물리계층 전체 세부기술 블록 대체 ML 응용 예

다. 그러나 통신시스템은 전송하는 신호조차도 우리가 유사하게 생성할 수 있고, 전송되는 채널도 수학적으로 잘 모델링되어 있으며, 수신기에서 출력해야 할 최적의 해가 무엇인지 알 수 있는 경우가 대부분이다. 이를 통해 입력과 정답으로 구성된 학습데이터를 원하는 만큼 충분히 얻을 수 있다. 그러나 또한 간과돼선 안 될 사항은 오프라인 학습에 사용된 데이터가 가지는 무선채널 환경과 온라인 무선채널 환경이 다를 경우 overfitting²⁾이 발생한다는 것이다.

III. 산학연 기관 동향

대부분 물리계층 분야보다는 전반적인 이동통신 시스템 관점에서 바라보고 있으므로 이에 대해 주요 산학연 기관 동향을 정리한다.

1. 삼성

6G 메가트랜드 중 하나로 AI-powered 클라우드 컴퓨팅과 AI-powered 디바이스 프로세싱을 제시한다[3-5]. 현 AI 기술은 대부분 클라우드 서비스

2) 과학계 오프라인 입력데이터에 대해 학습해 오차를 매우 감소시키면, 실제 데이터 적용 시의 오차가 오히려 증가하는 현상

에 의존한다. 그러나 지연을 줄이고 프라이버시를 보장하고 언제 어디서나 AI 서비스를 제공하기 위해서는 On-device AI capability가 필요하다. 이러한 AI는 전력 제약 만족, 학습 요건 만족 및 모델 축소와 최적화 등의 요구사항을 만족해야 한다. 이를 위해 삼성은 현재 새로운 소프트웨어 알고리즘과 툴을 지속적으로 개발하고 있다.

2. 에릭슨

미래 통신 인프라를 실시간·분산·책임지는 AI가 어디든지 편재할 것이라고 내다봤다. 실시간 AI는 실제 데이터 기반으로 지능적 결정과 실시간 예측 및 온라인 학습으로, 데이터센터, 네트워크 에지 및 단말로 분산된 AI는 통신 인프라에 분산된 데이터 기반의 글로벌 그리고 국부적 의사결정을 하는 것으로, 책임지는 AI는 안전과 신뢰 보장 및 투명성 제공으로 정의한다[6].

3. 노키아

B5G 인프라는 다중 연결성과 품질 예측이 필요한 고밀도 네트워크, 능동적인 네트워크 슬라이싱, 기계학습 기반 PHY-MAC(Medium Access Control) 계층, 인공지능과 기계학습이 도처에 존재하는 네트워크 자동화가 될 것이라 예상한다[7]. 이를 위해 분산된 데이터, ML과 컴퓨팅, 에너지 절감, 망 기능 관리, 빔 구성과 예측, ML 모델 배분과 관리 등의 필요성을 강조한다.

4. 화웨이

데이터 폭증으로 2030년까지 5G는 대부분 ML 기반으로 진화 발전해 지능형 네트워크의 제1시대

표 1 이동통신 기술과 AI 기술의 비교

	AI 기술	이동통신 기술
가치	데이터	링크
시나리오	자동	매뉴얼
타겟	글로벌 확률 최적화	국소 결정 최적화
범위	중단 간 네트워크	국부 네트워크
방법	빅데이터, 학습	공식, 최적화
사용	타겟 목표 설정	파라미터의 매뉴얼 조정

가 되고, 2030~2040년 6G는 AI를 위한 ML, 통신을 위한 ML, 클라우드/에지/디바이스로 광범위하게 퍼진 생각하는 지능형 네트워크의 제2시대가 올 것으로 전망한다[8,9]. 최근에 이동통신에 인공지능 기술을 적용하는 연구가 진행되고 있으며, 상위 계층, 네트워크 계층과 정보보호보다 PHY-MAC 계층에는 상대적으로 연구 실적이 적다는 분석 결과를 제시한다. 표 1은 화웨이가 언급한 인공지능 기술과 이동통신 기술 간 비교를 보여준다.

또한, 화웨이는 이동통신에서 무선채널의 내부 구조 이해, 무선자원 관리 및 네트워킹 등 모든 영역에서 매우 복잡한 문제가 AI로 해결할 과제로 본다[10]. 글로벌 문제해결 기반 AI만으론 불충분하고 기계가 새로운 상황과 환경을 인식하고 적응하는 능력과 함께 인간과 유사한 의사소통 및 추론을 하는 방법을 탐구해야 함을 제안한다.

5. DARPA & 프론트피어

DARPA는 데이터 폭증에 따른 AI의 진화 물결을

표 2 AI의 진화 물결

	주요 내용
1단계	좁게 정의된 문제에 대해 추론하지만 불확실
2단계	빅데이터로 훈련하고 통계 모델 생성
3단계	센싱과 전처리 후의 데이터로부터 추론

표 2와 같이 세 단계로 정의하면서[11], 현재 우리는 2단계 물결에 속해 있다고 언급한다.

오늘날 기계는 상황에 맞게 추론하는 기능이 없어 훈련은 모든 궁극점을 다루어야 하므로 비용이 많이 들고 현실성이 떨어져 실제 세계에서 배우는 것이 필요함을 역설한다. 인간은 다른 동물보다 근본적인 인과 관계에 대한 보다 정확한 내부 모델 덕분에 더 잘 일반화할 수 있다. 이를 반영해 3단계 물결 실현을 위해, 지각 프레임워크를 뛰어넘어 지각과 일부 마스터-슬레이브 훈련을 사용해 학습하는 프레임워크로 Grothendieck Topos라는 위상 수학의 도입을 제안한다.

프론트피어는 통신에 ML을 적용하면 부정확하거나 복잡한 모델로 인한 복잡성, 비효율적인 컴퓨팅과 느린 수렴속도를 개선할 수 있다고 언급한다. 또한, 구현 복잡도와 많은 측정을 줄일 수 있으며, 강건한 예측을 제공할 수 있다 하면서 표 3과 같이 ML 요구사항을 제시한다[12].

6. 오울루(Oulu) 대학

핀란드의 6G Flagship 과제를 주관하고 있는 오울루 대학은 세계최초로 6G 백서를 발표했다 [1]. 5G는 미래의 연결성 요구사항을 위한 플랫폼으로 지속적인 역할을 하겠지만, 불완전한 연결

표 3 이동통신용 ML 요구사항

순번	요구사항
1	불확실한 적은 통신데이터로 강건한 온라인 기계학습
2	이동통신 영역의 지식과 통신데이터 기반 ML 모델을 결합한 하이브리드 학습
3	주파수와 시간 등에서 느리게 변화하는 기능을 학습하면서 중요한 기능 특성을 보존하는 기능
4	희소성 있는 자원을 효율적으로 이용하는 분산 학습으로 빅데이터 해석을 위한 새로운 아키텍처
5	저복잡·저지연 구현을 가능케 하는 새로운 기술
6	통신 인프라 특성상 신뢰·안심할 수 있는 ML

성만으론 충분하지 않다고 한다[13]. 그 이유로 주변 환경과 통신하고 감지·행동하는 새로운 AI 디바이스가 증가하면 훈련 및 추론을 위해 모든 디바이스의 학습데이터를 클라우드로 전송할 수 없다.

IV. ML 기반 물리계층 기술 동향

주요 세부기술 분야에 관한 기술 동향과 이슈 및 표준화/구현 영향을 제공한다. 먼저 전체를 요약하면 표 4와 같다.

1. MIMO

가. 빔형성 기술

딥러닝을 적용한 빔형성 기술은 협력 빔형성, mmWave기반 송수신 빔형성, 대규모 아날로그 안

표 4 ML 기반 물리계층 세부기술 분류 및 분석 요약

중분류	소분류	표준화 영향	구현 영향
MIMO	빔형성	No	Yes
	간섭제어	Yes	Yes
채널코딩	채널복호	No	Yes
	최대우도추정	No	Yes
다중접속	SCMA 기반	Yes	Yes
	MIMO-NOMA 기반	Yes	Yes
신호추정	저해상도 신호추정	Yes	Yes
	Massive MIMO 신호추정	No	Yes
채널추정	채널 피드백	Yes	Yes
	채널추정	No	Yes
	채널 예측	No	Yes
동기	동기신호 기반	Yes	Yes
	FEC 기반	Yes	Yes
변복조	성상도 변경	Yes	Yes
	공간변조	Yes	Yes
위치측위	RSS/CSI 기반	Yes	Yes
	Hybrid 기반	Yes	Yes

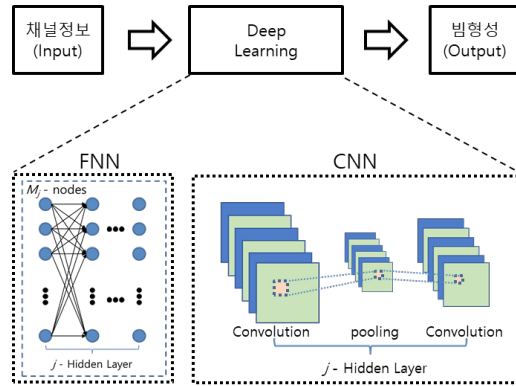


그림 3 빔형성 DL 구조

테나 환경에서의 빔형성 등 다양한 환경에서 연구가 진행되고 있다.

그림 3과 같이 학습 입력데이터는 채널정보치를 사용하고, 빔형성 결과 또는 빔형성을 결정하는 중요 파라미터치를 출력값으로 정한다. 학습 모델은 지도학습 형태의 FNN(Fully-connected Neural Network)과 CNN(Convolutional Neural Network)을 사용한다. 참고문헌 [14]에서는 다중 기지국(BS: Base-Station) 환경에서 전방향 빔으로 받은 채널정보치를 이용해 별도의 빔 스위핑 없이 빠른 협력 빔형성이 가능함을 보여준다. 참고문헌 [15]에서는 mmWave MIMO 환경에서 CNN을 적용해 최적의 아날로그 빔형성 송수신 쌍을 기존 기법들보다 더 빠르게 찾을 수 있음을 보여준다. 참고문헌 [16]에서는 많은 수의 안테나를 갖고 있는 mmWave MIMO 환경에서 FNN을 통한 빔형성 기법과 더불어, 오프라인 학습 및 온라인 배치에 관한 실제 적용기법에 관한 내용을 다룬다.

나. 간섭제어 기술

관련 DL 기반 기술 연구는 다수 송수신기 쌍으로 구성된 간섭채널 환경에서 주로 송신파워 조절 및 빔형성 기술을 통해 간섭을 제어하는 데 집중되

어 있다.

참고문헌 [17]에서는 다중 셀, 다수 사용자 MIMO 간섭 환경에서 FNN을 이용해 송신파워를 조절한다. 송신파워 레벨을 설정해 학습 net의 출력 범위를 좁힌 점과 레이어별 사전학습을 통해 성능 개선을 이끌어낸 점이 특징이다. 참고문헌 [18]에서는 다중 셀, 다중접속 채널환경에서 송신파워를 조절한다. 기존 반복적인 과정을 통해 송신파워 조절을 수행하는 WMMSE(Weighted Minimum Mean Square Error) 기법을 지도학습으로 반복 없이 빠르게 처리하면서도 유사한 성능을 보여준다.

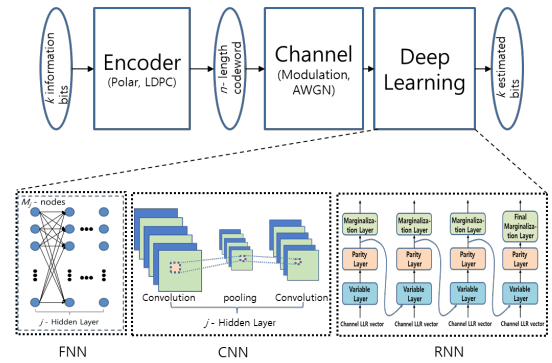


그림 4 채널복호기 DL 구조

다. 관련 이슈 및 표준화/구현 영향

구분	주요 내용
이슈	안테나 수 및 채널 변화에 강건한 학습 필요
	오프라인 학습 시 적용된 무선채널 모델과 온라인상의 실제 무선채널 환경이 불일치할 때의 성능 저하(이하 무선채널 불일치라 명명)
	오프라인 학습 시 적용된 SNR(Signal-to-Noise Ratio) 과 온라인상의 실제 SNRI이 불일치할 때의 성능 저하(이하 SNR 불일치라 명명)
표준화/구현 영향	협력 빔형성 및 효율적인 간섭제어를 위해 BS 간 채널 정보 공유 필요
	빔형성 경우, 대부분 기존 빔형성 수신 알고리즘을 대체할 수 있으므로 표준 규격화가 불필요하지만 구현을 고려한다면 별도의 연산장치 구현 요구
	간섭제어 경우, BS와 Central-Unit 간 정보교류를 위한 인터페이스 관련 표준 규격화가 예상되므로 의무적 구현 요구

2. 채널코딩

가. 채널복호 기술

전반적인 복호기 학습 구조는 그림 4와 같다. 학습 입력데이터는 무선채널을 겪은 변조된 코드워드(CW: Codeword)를 사용하고, 복호된 정보비트를 출력치로 정한다. 이때, 변조된 CW는 (1) 정보비트 생성, (2) 인코딩(예, Polar code), (3) 변조 과정

을 통해 생성한다.

DL 학습 모델은 FNN, CNN, RNN(Recurrent Neural Network) 등을 적용한다. 참고문헌 [19]에서는 HDPC(High-Density Parity-Check) 인코딩 환경에서 BP(Belief Propagation) 복호기를 모방하는 FNN, RNN net을 적용해 반복적인 동작 없이 최대우도추정 기법과 유사한 성능을 보여준다.

또한, Polar 인코딩 환경에서 학습 신호세기, DL net 노드 수 및 학습 코드 수와 같은 다양한 학습 파라미터에 관한 분석이 수행되었으며, 참고문헌 [20,21]에서는 동일 파라미터 환경에서 학습 모델(FNN, CNN, RNN)에 따른 성능을 분석한다. 이 밖에 정보비트 수 증가를 고려한 서브 CW 블록별 DL 학습[22], 메모리 복잡도를 고려한 극부호 연속제거 리스트 복호기 구현[23]도 연구되고 있다.

나. 최대우도추정 기술

특정 인코딩 기법을 고려한 기존 복호기 연구와 달리, 참고문헌 [24]에서는 최대우도추정 기법과 유사한 성능을 보이는 Sphere 복호기에 대한 연구를 수행한다. 이 복호기는 수신신호 세기를 고려해 후보 CW의 반경을 잡는 기술로, 반경을 작게 잡는 경우 후보군을 줄임으로써 복잡도를 낮출 수 있는 특징과 반경을 크게 잡을 경우 ML과 동일한 성

능을 얻는 특징을 가지고 있다. 즉, Sphere 복호기에서는 (1) 반경을 잡는 문제와 (2) 반경 내에 CW 수를 찾는 문제가 존재하게 된다. 해당 연구에서는 FNN을 사용해, 정해진 반경 내 CW 수를 찾도록 학습한다. 즉, Sphere 복호기를 완벽 대체하는 학습이 아닌, 복호기의 일부분(복잡도가 높은 부분)을 대체하는 보조적 역할로 학습을 수행하여 복잡도를 감소하면서 성능을 보전한다.

다. 관련 이슈 및 표준화/구현 영향

구분	주요 내용
이슈	긴 CW에 대한 복호 성능 부족, 현재는 대부분 짧은 길이의 CW에 대한 학습 결과만 제시
	기존 복호 기법과 연산 복잡도 및 시간 확인 필요
	CW 길이별로 학습 모델이 달라짐
	최대우도추정은 부분 보완 기술로 파급력이 낮음
표준화/구현 영향	채널복호 경우, 수신기 이슈라 표준 규격 불필요하고, 현실적 이슈(CW 길이 및 소요시간)를 해결하면 성능 측면의 이득이 있어 구현 영향 있음
	최대우도추정 경우도 수신기 이슈로 표준 규격 불필요하지만, 해당 기술이 실제 구현 가능 시 송신 인코딩 기술에 변화를 줄 수 있으므로, 향후 표준 규격화 가능성이 매우 큼

3. 다중접속

가. SCMA 기반 무선접속 기술

기존 SCMA(Sparse Code Multiple Access) 방식에서 BS는 일반적으로 각 사용자의 CSI(Channel State




그림 5 6개 신호열과 4개 자원을 가지는 SCMA

Information), 성상도 패턴 등 다양한 방법을 통해 생성된 코드북을 이용해 자원을 중첩 할당한다. 그림 5와 같이 다수의 사용자 스트림을 한정된 무선 자원에 할당하여 전송하는데, 6개의 사용자 신호열이 4개의 자원에 코드북 기반으로 중첩하여 할당함을 보여준다[25].

이러한 코드북을 DNN(Deep Neural Network)의 AE를 이용해 비트오류율을 최소화하도록 자동 생성하고 디코딩 블록에서도 DNN을 적용해 기존 SCMA보다 더 낮은 복잡도와 우수한 성능을 보이는 D-SCMA(Deep learning-aided SCMA)를 제안한다[25]. 또한, 수신에서 DNN을 적용해, 기존 SIC(Successive Interference Cancellation) 기법을 이용하는 MPA(Message Passing Algorithm) 기술을 대체함으로써 비트오류율 성능을 유사하게 유지하면서 복잡도와 디코딩 시간지연 문제를 획기적으로 개선한다.

나. MIMO-NOMA 기반 무선접속 기술

MIMO-NOMA(Non-Orthogonal Multiple Access) 시스템의 불완전한 SIC 간섭제거 오류를 반영해 실제 구현이 가능하면서도 성능이 우수한 DL 기반 프리코더와 SIC 디코더 기법이 있다[26]. 일반적으로, MIMO-NOMA 시스템에서 기지국이 여러 사

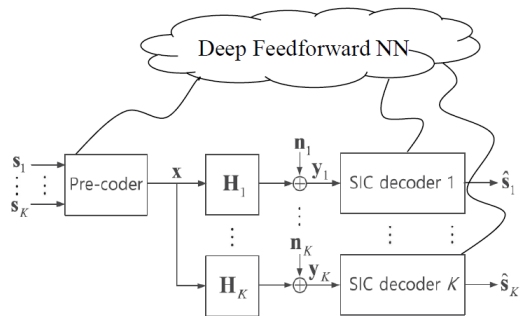


그림 6 DL 기반 MIMO-NOMA 구조

용자에게 동시에 데이터를 전송할 때 여러 사용자 데이터에 중첩코딩을 적용해 전송하고 단말은 SIC 디코딩을 수행해 신호를 복원한다.

그림 6과 같이 순방향 송신부의 프리코더와 수신부의 SIC 디코더에 대해 각 사용자의 MSE(Mean Squared Error)가 최소화되게 하도록 DNN을 적용한다. 수신부 SIC의 디코더는 오류없이 완벽히 동작된다고 가정하는 기존 연구와는 달리, SIC 디코더는 디코딩과 간섭신호 제거과정이 모두 불완전하다고 가정해 실제 환경에 적용될 수 있는 기법을 제안한다.




그림 7 ML 기반 저해상도 신호추정 프레임 구성 예

드의 신호들을 실시간 훈련시킨다. 훈련필드는 MIMO 송신단에서 가능한 변조신호의 모든 성상들과 이들에 대한 L 번 반복으로 구성된다. 이를 통해 신호추정 자체의 간소화와 저해상도 신호의 저복잡도 시스템이 구성된다.

다. 관련 이슈 및 표준화/구현 영향

구분	주요 내용
이슈	무선채널 불일치 해결 요구
	SNR 불일치 해결 요구
표준화/구현 영향	BS와 사용자 단말 모두에 표준 규격화 요구
	SCMA 경우, 코드북 표준화에 따른 구현 필수
	MIMO-NOMA 경우, SIC 디코딩과 SIC의 복잡도 개선 구현 요구

4. 신호추정

가. 저해상도 신호추정 기술

기존 신호추정 방식은 부동소수점 채널추정치 를 기반으로 수신신호에서 선형적인 송신신호 특성과 미리 알려진 변조매핑률을 반대로 적용한다. 이 때문에 부동소수점 수치에 근접한 해상도를 가질 때 성능이 보장되며, 이에 따라 massive MIMO의 경우 구현 복잡도가 자연히 증가한다. 이러한 복잡도 증가를 해결하고자 저해상도(1 또는 2비트)의 신호 기반 ML 기법이 제안된다[27].

그림 7과 같이, CSI 정보 없이 미리 알려진 훈련필드의 신호열을 바탕으로 실제 수신된 훈련필

나. Massive MIMO 신호추정 기술

고해상도 신호는 유지하되, 기존의 최적 수학적 접근방식과 ML을 결합한 신호추정 방식이 제안된다[28]. 이 방식에서는 MIMO의 공간 스트림을 수신단에서 추정하기 위해, 수신신호의 선형 성분은 DFE(Decision Feedback Equalizer)와 ZF(Zero-Forcing)을 결합한 등화기로 입력시킨다. 또한, 비선형 성분은 DNN net을 적용해 학습시켜 그 결과를 상기 등화기에 입력시켜 출력치를 구하고 이를 다시 상기 학습 결과치와 비교해 최종적으로 신호를 추정한다.

다. 관련 이슈 및 표준화/구현 영향

구분	주요 내용
이슈	저해상도 신호추정 경우, 온라인상에 학습을 적용하므로 무선채널/SNR 불일치 문제는 없으나, 고차원 변조일수록 모든 가능한 성상 수가 기하급수적 증가하므로 훈련필드 자원 증가 불가피하고, 훈련필드 내 학습이 가능한 고성능·고속처리 ML 모델 요구
	Massive MIMO 신호추정 경우, 오프라인 학습이 연구되고 있으므로 무선채널/SNR 불일치 문제해결 요구
표준화/구현 영향	저해상도 신호추정 경우, 훈련필드에 대한 표준 규격화가 요구되므로 이에 따른 구현은 필수
	Massive MIMO 신호추정 경우, 수신기 이슈로 표준 규격 불필요하지만 이슈해결 시 높은 구현 가능성 존재

5. 채널추정

가. 채널 피드백 기술


FDD(Frequency Division Duplex) 기반 종래 massive MIMO 시스템에서 최적 전송용량 달성을 위해선 그림 8과 같이 각 사용자가 추정한 CSI는 BS로 피드백되어야 한다.

그런데 BS의 안테나 수가 증가할수록 과도한 피드백 오버헤드가 발생할 수 있으므로, 이를 줄이기 위해 DL의 AE 기반 기술이 제안된다[29,30].

그림 9와 같이, 사용자 단말은 AE net의 encoder를 통해 추정된 CSI의 특성을 추출하여 압축한다. 다음, BS는 AE net의 decoder를 통해 추출된 CSI의 특성으로부터 CSI를 복원하도록 비압축한다.

나. 채널추정 기술

안테나마다 하나의 RF chain이 사용되는 massive



출처 Y. Liao et al., "CSI feedback based on deep learning for massive MIMO systems," *IEEE Access*, vol. 7, 2019.

그림 8 Massive MIMO 시스템의 다이어그램




그림 9 AE 기반 압축 및 비압축의 개념적 구조

MIMO 시스템에 DL 기반 저속 이동성 지원 채널 추정 기술이 있다[31]. 이는 안테나 수 증가에 따라 하드웨어 고비용과 전력 소모 증가가 발생한다. 이를 해결해 RF chain 수를 줄인 beamspace channel model과 렌즈 어레이 기반 massive MIMO 시스템에 적용되는 DL 기반 저속 이동성 지원 채널추정 기술이 있다[32].

고속 이동성 지원 채널추정을 위해 기존에는 DPA(Data-Pilot Aided) 방법을 사용하는데, 데이터를 파일럿으로 사용함에 따른 EP(Error Propagation)가 발생해 성능이 열화된다. 부반송파 간 채널의 상관성에 기반해 상기 EP를 저감하기 위해 기존 DPA 방법과 결합한 AE 기반 채널추정 기술이 있다[33].

다. 채널 예측 기술

FDD 시스템에서 그림 10(a)의 종래 통신 과정과는 달리, 그림 10(b)와 같이 UL(Uplink)-CSI로부터 딥러닝 학습 기술을 이용하여 직접 DL(Down-link)-CSI를 예측한다[34]. 딥러닝 모듈은 DL-CSI와 UL-CSI 사이의 시공간 상관성을 학습하는 특성 추출 모듈과 추출된 특성으로부터 DL-CSI를 예측하는 예측 모듈로 구성된다.

UL-CSI로부터 DL-CSI를 예측하는 것을 시공간 이미지 예측 문제로 간주한다. 또한, 채널의 시




그림 10 FDD 시스템 (a) 종래 과정 (b) 채널 예측과정

변 특성을 고려하기 위해, UL-CSI로부터 DL-CSI를 예측하는 것을 시간 시퀀스 예측 문제로 간주한다.

라. 관련 이슈 및 표준화/구현 영향

구분	주요 내용
이슈	채널 피드백 경우, CSI 피드백 시 사용되는 자원을 최소화하기 위해 압축률을 높이면서 성능을 보전하고, 압축 손실을 최소화하는 AE 개발 요구
	채널추정 경우, 기존 알고리즘 기반 채널추정 기법에 비해 낮은 복잡도 달성 요구
	채널추정 경우, 종래의 알고리즘 기반 채널추정을 대체하거나 이동성 요구 환경에선 상호 보완적 적용
	채널 예측 경우, 매우 반대하게 다양한 순방향 주파수대역 f1과 역방향 주파수대역 f2 간 차이들에 대한 오프라인 학습 요구
	무선채널/SNR 불일치 문제해결 요구
표준화/구현 영향	채널 피드백 경우, BS와 사용자 단말은 각각 decoder와 encoder를 오프라인 학습해 미리 알고 있어야 하므로 표준 규격화 요구
	채널 피드백 경우, 표준화에 따라 의무적으로 구현되어야 하며, 기존 대비 낮은 구현 복잡도 요구
	채널추정 경우, 수신 이슈로 표준화 불필요하고 저복잡도를 가지는 채널추정 구현 가능
	채널 예측 경우, UL-CSI 추정하는 것은 구현 이슈이고, 이로부터 DL-CSI를 예측하므로 표준 불필요
	채널 예측 경우, 그러나 온라인상 학습된 DL net을 효율적으로 사용하기 위해 f1와 f2 간 차이에 대한 어떠한 시그널링이 필요하다면 표준 이슈화 가능

6. 동기

가. 동기신호 기반 기술

동기를 포함해 송신기, 채널 모델 및 수신기 전체 종단 간 AE 기반 통신 시스템은 향후 10년 뒤 어찌면 글로벌 최적 성능을 달성할 가능성이 있다. 그러나 송수신기 간 샘플시간오프셋과 샘플주파수오프셋이 존재할 때 하나의 AE 기반 DL net으로 동기부터 복조까지 모두 수행하기에는 아직은 시기상조이다. 최근 시작된 연구에서는 그림 11과 같

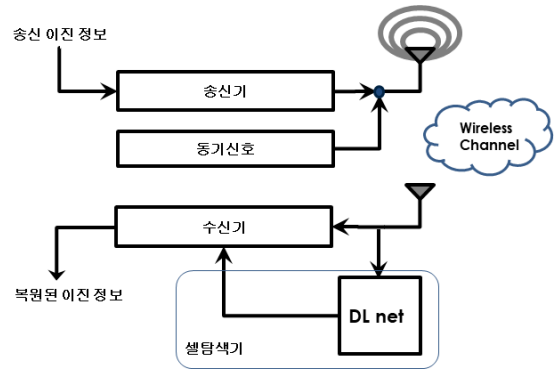


그림 11 동기신호 기반 DL 동기 시스템 구조

이 송신부가 보낸 동기신호(일반적으로 프레임의 맨 앞에 배치)가 송신부로부터 수신된다는 가정하에 기존 상호상관 기반 동기 획득 기술을 대체하는 DL 기반 동기 획득 기술에 대한 연구가 진행되고 있다[35].

수신부 샘플색기는 샘플시간오프셋을 추정해 프레임 동기를 획득하고 샘플주파수오프셋과 반송주파수오프셋을 추정해 주파수 동기를 획득하기 위해 데이터를 복원하는 수신기와 분리된 CNN을 구성한다. 이러한 DL 기법을 사용할 때 동기신호가 어떻게 구성되는지에 따라 동기 성능이 좌우된다.

나. FEC 기반 기술

일반적으로 통신에 널리 사용하는 FEC(Forward Error Correction)에 포함되어 있는 redundant 정보에 DL을 적용해 동기를 획득한다[36]. 이 방법은 기존 알고리즘 기반 방법에 비해 계산 복잡도가 높고 더 큰 메모리가 필요하지만, 별도의 동기신호가 필요 없어 전송속도가 향상된다. 또한, FEC마다 redundant 정보를 이용한 동기를 수행한 후 이때의 DL 결과들을 데이터 정보의 decoding을 위한 soft decision 입력으로 재사용하면 데이터 복원 성능이 향상될 수 있다. 이 방법에 대한 구체적 설명과 결

과가 불충분해 아직은 개념 단계이지만, 향후 진정한 종단 간 AE기반 통신시스템을 실현하는 데 기여할 가능성이 있다고 본다.

다. 관련 이슈 및 표준화/구현 영향

구분	주요 내용
이슈	무선채널 자체를 추정하는 것이 아니라 송신된 신호와 수신 신호 간 상관을 통해 동기를 획득하므로 무선채널/SNR 불일치 문제는 어느 정도 해소 가능
	반송주파수오프셋, 샘플주파수오프셋 및 고속 이동성이 존재하는 환경에서 성능 저하 방지 연구 필요
표준화/구현 영향	FEC 기반 기술 경우, 계산 복잡도와 소모 메모리 감소에 대한 개선과 개념 단계를 벗어난 결과와 충분한 이론 연구 필요
	동기신호 기반 기술 경우, 무선채널 환경이 변하더라도 효과적 오프라인 학습이 되게 하는 동기신호 설계가 중요하므로 표준 규격화가 필요하며, 이에 맞추어 동기 획득 복잡도를 개선하는 구현 요구
	FEC 기반 기술 경우, 효과적 오프라인 학습이 되게 하는 FEC의 redundant 정보가 설계되어야 하므로 표준 규격화되어야 하고, 낮은 계산 복잡도와 작은 메모리의 요구 사항을 만족하는 구현 필요

7. 변복조

가. 성상도 변경 기술

샤논이 정의한 무선 채널용량에 관한 수식 $C = \max_{p(x)} I(X; Y)$ 에서 $I(X; Y)$ 와 $p(x)$ 는 각각 입력 및 출력의 mutual information과 입력이 갖는 분포를 의미하며, 입력 분포가 가우시안 분포를 따를 때 최대 용량을 달성한다. 그러나 실제 입력 분포는 비트의 랜덤성을 고려해 일정한 분포를 사용하므로, 그에 따른 채널용량 손실이 발생한다.

용량 손실을 줄이는 방법으로, PS(Probabilistic Shaping) 방식과 GS(Geometric Shaping) 방식이 있다. PS는 기존 성상도의 모습은 그대로 하되, 각 포인트가 출력되는 확률을 가우시안 분포처럼 변경하는 기술이다. GS는 성상도를 변경해 용량 손실을 방지한다. 이에 대한 DL 기반 연구에서는 입력 분




그림 12 성상도 변경 기술 분류
(a) 확률론적 형태(PS) (b) 기하학적 형태(GS)

포, 변조기 및 복호기를 동시에 종단 간 학습해 입력 분포 또는 성상도를 변경한다[37].

나. 공간변조 기술

공간변조 기술은 그림 13과 같이 기존 변조기법과 달리 활성화된 송신 안테나의 인덱스 변화를 통해 데이터를 전송하는 것을 특징으로 한다. 공간변조 기법에 사용되는 기술은 안테나 선택과 안테나별 송신파워 조절을 기반으로 하고 있으며, 위 두 가지를 동시에 만족하는 DL 기반 공간변조 기법이

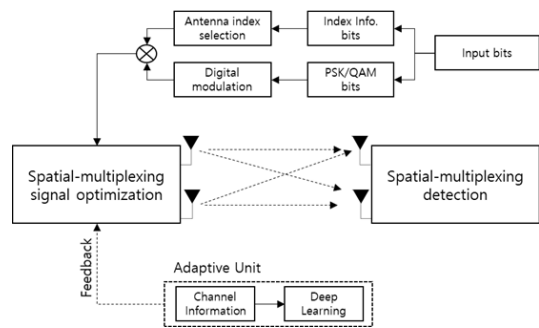
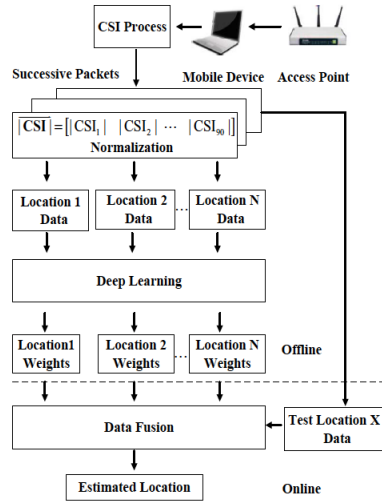


그림 13 공간변조 시스템 모델

연구되고 있다[38].

다. 관련 이슈 및 표준화/구현 영향

구분	주요 내용
이슈	성상도 변경 경우, 성상도 기반 무선 통신 시스템에 적용 가능하지만, 채널코드를 고려한 설계 요구
	공간변조 경우, 무선 채널변화에 민감할 것으로 예상되는 바, 이를 완화할 수 있는 기술 요구
표준화/구현 영향	송신부 변경이 필요하므로 표준 규격화가 필요하고, ATSC 3.0 표준에 일종의 GS 기반 기술 채택 참조
	표준 규격화 요구에 따라 구현은 필수



8. 위치측위


기존 수학적 위치측위 기술의 다중경로와 낮은 SNR 환경에서의 높은 측위 오차 문제를 해결하는 수단으로 ML 기반 연구가 진행되고 있다.

가. CSI 기반 위치측위 기술

RSS(Received Signal Strength)를 이용한 DL 기반 위치측위 기술[39]이 있으나 CSI 기반 위치측위 기술이 성능 우위에 있다. 2.4GHz WiFi 시스템의 부반송파별 CSI의 진폭치³⁾를 이용한 ML 기반 실내 위치측위가 있다[40]. 그림 14는 제한된 학습 모델의 구조와 실험환경을 보여준다. 오프라인에서는 다양한 여러 기준위치($i = 1, 2, \dots, N$)에서 측정된 CSI를 토대로 최적의 가중치를 계산한 다음, 온라인상에서 단말의 위치 \hat{L} 를 예측한다.

$$\hat{L} = \sum_i \text{Pr}(L_i | v) L_i \quad (1)$$

여기서, v 는 온라인에서 측정된 실험 단말 위치에서의 CSI를 의미하고 L_i 는 i 번째 기준위치를 의



출처 X. Wang, L. Gao, and S. Mao, "BiLoc: Bi-modal deep learning for indoor localization with commodity 5GHz WiFi," *IEEE Access*, 2017.

그림 14 CSI 기반 위치측위 AE net 구조 및 실험환경

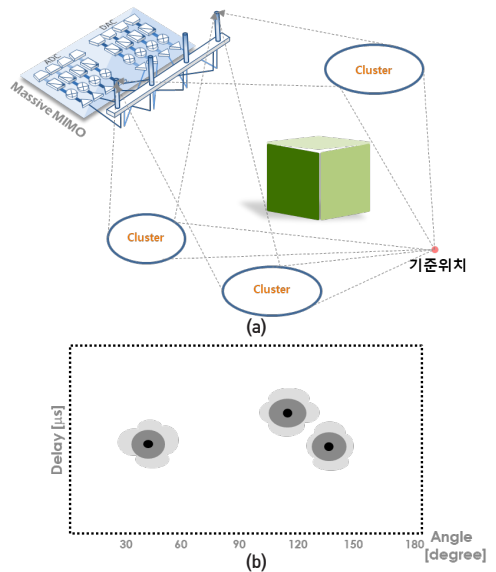


그림 15 실험 환경과 angular-delay 영역의 snapshot
(a) Massive MIMO 실험환경
(b) Angular-delay 영역의 snapshot 일 예

3) 진폭 외 위상 또는 진폭과 위상 모두 이용 가능하다.




그림 16 Massive MIMO 채널의 변환 과정

미하고 $P_r(L_i | v)$ 는 그림 14의 오프라인 DL 학습의 출력으로 0~1의 확률값을 가진다.

또한, massive MIMO 형태의 시스템에서 CSI 대신 CSI를 angular-delay 영역의 데이터로 변형해 학습하는 방법이 있다[41]. Massive MIMO의 변형된 채널에 대한 scarcity를 이용한 fingerprint 기반 측위 기술로서, 규칙적으로, $\{x_i\}$ 는 training observation i 의 단일 안테나 단말 좌표 벡터 집합을 의미하고, 그림 15(a)의 기준위치가 하나의 좌표 예이다. $f(i)$ 는 CSI Y_i 를 변형한 함수로서 $f(i) = s(Y_i)$ 로 표현된다. 더 정보적인 CSI의 sparse representation을 얻기 위해 그림 15(b)와 그림 16과 같이, $s(Y_i)$ 는 CSI에 2차원 discrete Fourier transform을 취한(즉, $s(Y_i) = FY_iF^H$) snapshot이다. 이렇게 구한 snapshot(즉, fingerprint)을 입력데이터로 삼아 해당 좌표를 구하는 오프라인 학습 결과를 앞서 언급한 식 (1)에 대입해 실험 단말의 위치를 예측한다.

나. 하이브리드 기반 위치측위 기술

입력데이터에 다양성과 정확도 개선을 위해 모바일폰에 내장된 자기장 센서 기능과 RSS/CSI 이용 DL 기반 fingerprint 기술을 결합해 실내 위치측위를 한다[42].

다. 관련 이슈 및 표준화/구현 영향

구분	주요 내용
이슈	무선채널/SNR 불일치 문제해결 요구
	기준위치로부터 주기적으로 학습의 입력데이터를 피드백 받아 온라인 학습을 수행하는 시스템 구축이 가능하므로 상기 불일치 해결 가능성 상존
표준화/구현 영향	보다 정확한 채널정보 측정을 위한 training signal 설계가 필요하고 기준위치별 주기적 보고에 대한 절차가 필요하므로 표준 규격화 요구
	가시거리/비가시거리 신호가 혼재된 상황에서도 성능향상이 가능한 저지연·저복잡 구현 요구

V. 연구의 방향성 및 전망

아직은 초기 연구단계이지만 분석된 ML 기반 물리계층 기술의 동향을 바탕으로 2030년경까지의 연구 방향성과 산업/시장에 미치는 영향 및 기술의 불확실성에 대해 전망한다.

1. 연구 방향성

그림 17과 같이 2가지 연구 방향성을 제시한다. 첫째는 MOLA(Multi-Offline Learning and Adaptation)로 정의된다. 즉, 다수의 채널 모델에 대한 오프라인 학습을 미리 수행해 시스템에 파일업했다가 실제 무선채널 특성을 모니터링해 이에 맞는 오프라인 학습을 적응적으로 적용한다. 둘째는 SOLO(Single Offline Learning and Online Learning)로 정의된다. 즉, 무선채널 특성 요인별 민감도를 규명해 민감도가 가장 낮은 요인을 기준으로 오프라인 학습을 수행해 실제 시스템에 적용하고, 온라인 상 실제 무선채널 특성에 적응하도록 하는 온라인 학습을 더한다.




그림 17 ML 기반 물리계층 기술의 연구 방향성

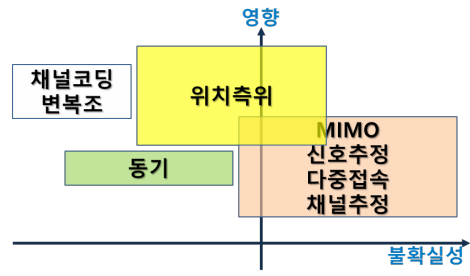


그림 18 영향 및 불확실성

그림 17과 같이 지금으로부터 x 년⁴⁾까지는 MOLA와 SOLO가 평행선을 달릴 것으로 전망된다. 다음, y 년 이후에는 무선채널 상황에 따라 MOLA와 SOLO 중 하나로, 때에 따라 선택적 적용 또는 결합적 적용이 예상된다.

2. 영향 및 불확실성

6G 서비스 자체 측면에서 아무리 수요가 높다 하더라도 기본적으로 기존 수학적 알고리즘 기반 기술 대비 저복잡도로 고성능 구현이 가능한 ML 기반 기술이 뒷받침되지 않는다면 산업과 시장에 미치는 영향도 그에 따라 미미할 것이다. 따라서 ML의 학습이 수행되는 영역이 무선채널 보상 전인지 보상 후인지에 따라 6G 통신인프라에 미칠 세부기술별 영향 및 불확실성이 좌우될 것으로 전망된다.

그림 18과 같이 무선채널 보상 전 영역에는 MIMO, 동기, 위치측위, 신호추정, 다중접속 및 채널추정이 포함되고, 보상 후에는 채널코딩과 변복조 기술이 포함된다.

위치측위, MIMO, 신호추정, 다중접속 및 채널

추정 기술은 무선채널 불일치로 인한 성능 저하를 방지하는 것이 매우 중요하며 그림 17의 연구 방향을 통해 극복될 수 있는지 앞으로 지켜볼 필요가 있다. 그에 반해 동기 기술은 무선채널 자체를 추정해 사용하는 것이 아니라 주어진 무선채널에 대해 동기신호 길이 이상의 상관을 수행해 데이터가 실려 있는 프레임 시작점을 찾아낸다. 그러므로 순시적으로 변화하는 무선채널 특성을 추적하지 않고 의도적으로 무선채널의 통계적인 특성을 추적하도록 할 수 있다. 이렇게 함으로써 무선채널 불일치 문제를 어느 정도 해결할 수 있으므로 기술의 불확실성은 무선채널 보상 전 기술 중 가장 낮을 것으로 전망된다. 한편, 위치측위 분야 중 실내측위 기술에 한정하면 기준위치로부터 주기적으로 학습의 입력데이터를 피드백 받아 온라인 학습을 수행하는 시스템 구축이 용이할 수 있으므로 무선채널 불일치 문제해결이 어느 정도 가능할 것으로 전망된다. 또한, 위치측위 기술은 공장자동화, 차량사물통신, 자율주행 및 치매환자 실종 방지 등 새로운 6G 초정밀 서비스로 각광받을 것으로 전망된다.

채널코딩과 변복조 기술은 무선채널 보상 후를 전제하므로 무선채널의 영향은 colored noise 형태로 상당히 줄어들 수 있다. 이 때문에 앞으로 이러한 colored noise에 둔감하면서 가우시안 noise 채널

4) 무선채널 불일치에 의한 성능 열화의 정도에 따라 세부기술 별로 x 가 다를 수 있으며, 가장 작은 x 값으로 나열하면 채널코딩 < 변복조 < 동기 < 위치측위 < MIMO < 신호추정 < 다중접속 < 채널추정 순이다.

의 성능을 따르는 연구를 진행한다면 기술적인 불확실성이 가장 낮고 이에 따라 표준화 및 구현 영향도 높을 것으로 전망된다.

VI. 결론

2030년경이면 초성능, 초공간, 초정밀 및 초연결의 특성을 가지는, 5G와 차별화되는, 통신 인프라가 시작될 것이다. 이러한 특성들을 변혁적으로 만드는 열쇠는 이들에 편재되는 AI 기반 기술의 괄목상대한 발전에 있을 것이다. AI 네트워킹은 현재도 상용화를 시작할 만큼 기존 방법 대비 장점이 있지만, AI 물리계층은 풀어야 할 문제들이 산재해 있다. 이에 따라 본 고에서는 AI 기반 물리계층 세부기술들에 관한 기술 동향과 함께, 문제해결을 위한 연구의 방향성과 산업 영향 및 기술 불확실성에 대한 견해와 전망을 제공하였다.

참고문헌

- [1] 6G Flagship, "Key drivers and research challenges for 6G ubiquitous wireless intelligence," *6G Research Vision 1*, September 2019.
- [2] T. J. O'Shea and J. Hoydis, "An introduction to deep learning for the physical layer," *IEEE Trans. Cognitive Commun. Netw.*, vol. 3, 2017, pp. 563-575.
- [3] J. Lee, "Moving toward 6G," *6G Wireless Summit*, Samsung, March 26, 2019.
- [4] Samsung Research, "Artificial intelligence," <https://research.samsung.com/artificial-intelligence>.
- [5] Samsung Research, "6G Vision: The next hyper-connected experience for all," <https://research.samsung.com/#>, 2020.
- [6] M. Frodigh, "Towards a connected intelligent future," *6G Wireless Summit*, Ericsson, March 26, 2019.
- [7] H. Sanneck, "Beyond 5G and artificial intelligence panel," *EUCNC 2019*, June 21, 2019.
- [8] M. Debbah, "Beyond 5G: What will it be?" *6G Wireless Summit*, March 24, 2019.
- [9] P. Zhu, "B5G + AI: Innovation for next decade," *EUCNC 2019*, June 21, 2019.
- [10] J. C. Belfiore et al., "Towards an intelligent 6G," *6G Wireless Summit*, March 26, 2019.
- [11] <https://www.darpa.mil/attachments/AIFull.pdf>
- [12] S. Stanczak, "Beyond 5G and artificial intelligence panel-Machine learning for communication," *EUCNC 2019*, June 21, 2019.
- [13] M. Bennis, "Wireless network intelligence," *6G Wireless summit*, Univ. of Oulu, March 26, 2019.
- [14] A. Alkhateeb et al., "Deep learning coordinated beamforming for highly-mobile millimeter wave systems," *IEEE Access*, vol. 6, 2018, pp. 37328-37348.
- [15] A. M. Elbir, "CNN-based precoder and combiner design in mmWave MIMO systems," *IEEE Commun. Lett.*, vol. 23, no. 7, July 2019, pp. 1240-1243.
- [16] T. Lin and Y. Zhu, "Beamforming design for large-scale antenna arrays using deep learning," arXiv: 1904.03657, 2019.
- [17] M. A. Wijaya, K. Fukawa, and H. Suzuki, "Intercell-interference cancellation and neural network transmit power optimization for MIMO channels," in Proc. *VTC2015-Fall*, Boston, MA, 2015.
- [18] H. Sun et al., "Learning to optimize: Training deep neural networks for interference management," *IEEE Trans. Signal Process.*, vol. 66, 2018, pp. 5438-5453.
- [19] E. Nachmani, Y. Be'ery, and D. Burshtein, "Learning to decode linear codes using deep learning," in Proc. *UIUC*, Monticello, IL, 2016, pp. 341-346.
- [20] T. Gruber et al., "On deep learning-based channel decoding," in Proc. *CISS*, Baltimore, MD, 2017.
- [21] W. Lyu et al., "Performance evaluation of channel decoding with deep neural networks," in Proc. *ICC*, 2018.
- [22] S. Cammerer et al., "Scaling deep learning-based decoding of polar codes via partitioning," in Proc. *GLOBECOM*, 2017.
- [23] M. Zhao et al., "Decoding binary linear codes using penalty dual decomposition method," *Commun. Letters*, vol. 23, no. 6, June 2019, pp. 958-962.
- [24] A. Askri and G. Othman, "DNN assisted sphere decoder," in Proc. *ISIT*, Paris, 2019.
- [25] M. Kim et al., "Deep learning-aided SCMA," *IEEE Commun. Lett.*, vol. 22, no. 4, Apr. 2018.
- [26] J.-M. Kang et al., "Deep learning-based MIMO-NOMA with imperfect SIC decoding," *IEEE Syst. J.*, 2019, pp. 1-4.
- [27] Y.S. Jeon, S.N. Hong, and N. Lee, "Blind detection for MIMO systems with low-resolution ADCs using supervised learning," in Proc. *ICC*, 2017.
- [28] Z. Jia, W. Cheng, and H. Zhang, "A partial learning based detection scheme for massive MIMO," *Wireless Commun. Lett.*, vol. 8, 2019, pp. 1137-1140.
- [29] Y. Liao et al., "CSI feedback based on deep learning for massive MIMO systems," *IEEE Access*, vol. 7, 2019, pp. 86810-86820.

- [30] C.-K. Wen, W.-T. Shih, and S. Jin, "Deep learning for massive MIMO CSI feedback," *Wireless Commun. Lett.*, vol. 7, no. 5, 2018, pp. 748-751.
- [31] H. Huang et al., "Deep learning for super-resolution channel estimation and DOA estimation based massive MIMO system," *IEEE Trans. Veh. Technol.*, vol. 67, no. 9, Sept., 2018, pp. 8549-8560.
- [32] H. He et al., "Deep learning-based channel estimation for beamspace mmWave massive MIMO systems," *Wireless Commun. Lett.*, vol. 7, no. 5, Oct., 2018, pp. 852-855.
- [33] S. Han, Y. Oh, and C. Song, "A deep learning based channel estimation scheme for IEEE 802.11p systems," 2019.
- [34] J. Wang et al., "UL-CSI data driven deep learning for predicting DL-CSI in cellular FDD systems," *IEEE Access*, vol. 7, 2019, pp. 96105-96112.
- [35] H. Wu, Z. Sun, and X. Zhou, "Deep learning-based frame and timing synchronization for end-to-end communications," *J. Phys.*, vol. 1169, 2018.
- [36] T.A. Chadov, S.D. Erokhin, and A.I. Tikhonyuk, "Machine learning approach on synchronization for FEC enabled channels," in Proc. *SYNCHROINFO*, 2018.
- [37] M. Stark, F. Aoudia, and J. Hoydis, "Joint learning of geometric and probabilistic constellation shaping," arXiv: 1906.07748, 2019.
- [38] P. Yang et al., "Adaptive spatial modulation MIMO based on machine learning," *IEEE J. Selected Areas Commun.*, vol. 37, no. 9, 2019, pp. 2117-2131.
- [39] X. Wang et al., "DeepFi: Deep learning for indoor fingerprinting using channel state information," in Proc. *WCNC*, 2015.
- [40] X. Wang, L. Gao, and S. Mao, "BiLoc: Bi-modal deep learning for indoor localization with commodity 5GHz WiFi," *IEEE Access*, vol. 5, 2017, pp. 4209-4220.
- [41] J. Vieira et al., "Deep convolutional neural networks for massive MIMO fingerprint-based positioning," in Proc. *PIMRC*, 2017.
- [42] W. Zhang et al., "DeepPositioning: Intelligent fusion of pervasive magnetic field and WiFi fingerprinting for smartphone indoor localization via deep learning," in Proc. *ICMLA*, 2017.