

최신 기계학습 기반 동적 주파수 공유 기술 동향

윤 장 혁 · 정 방 철

아주대학교

I. 서 론

무선 데이터 트래픽은 스마트폰의 보편화, 사물인터넷(IoT) 단말의 폭증, 그리고 5G를 넘어 6G로 향하는 이동통신의 진화와 함께 기하급수적으로 증가하고 있다. 실제론 시장 전망에 따르면 전 세계 모바일 데이터 트래픽은 2024년 말 대비 2030년까지 약 2.5배 늘어 월 300 엑사바이트(EB)를 넘어설 것으로 예측되며, 전체 트래픽에서 5G가 차지하는 비중도 같은 기간 약 34%에서 80% 수준으로 높아질 것으로 전망된다^[1]. 이러한 수요를 감당하기 위해 국제전기통신연합 전파부문(ITU-R)은 2023년 11월 6G의 개념적 틀인 IMT-2030 프레임워크 권고를 승인하였다^[2]. 이 권고는 기존 5G에 없던 ‘인공지능(AI)과 통신’ 및 ‘통합 센싱-통신(ISAC, integrated sensing and communication)’을 새로운 이용 시나리오로 제시하여, 앞으로의 무선 시스템이 인공지능과 센싱을 근본 요소로 포함할 것임을 분명히 하였다.

문제는 무선 주파수 자원이 물리적으로 유한하다는 점이다. 특히 광역 서비스에 유리한 6 GHz 이하의 이른바 ‘황금 주파수(golden band)’ 대역은 이미 배타적으로 할당되어 여유 대역이 거의 남아 있지 않다. 세계전파통신회의(WRC-23)에서 상위 6 GHz(6.425~7.125 GHz) 대역을 지역에 따라 국제이동통신(IMT)용으로 식별하고, 7 GHz 이상의 상위 중대역(upper mid-band)을 차기 6G 후보로 연구하기로 한 것도 이러한 압박을 보여준다. 이 대역은 넓은 대역폭과 양호한 전파 특성을 겸비하지만 위성·전파천문 등 기존 사용자와의 공존을 전제로 한다^[3]. 그러나 새로운 대역을 개척하는 것만으로는 한계가 있으며, 이처럼 신규 주파수 확보가 어려워진 상황을 흔히 ‘스펙트럼 고갈(spectrum gridlock)’이라 부르며, 정적 할당이 낡은 이러한 비효율은 최근의 인지무선 연구에서도 출발점으로 다루어진다^[4].


역설적이게도 여러 실측 연구는 이미 할당된 대역의 상당 부분이 시간적·공간적으로 저활용(underutilized)되고 있

음을 일관되게 보고해 왔다. 사용 권리가 배타적으로 부여되어 있을 뿐, 그 주파수가 모든 시간과 장소에서 쓰이는 것은 아니다. 이러한 관찰은 ‘정적(static)·배타적 할당’에서 ‘동적(dynamic) 공유’로의 전환을 뒷받침한다. 하나의 대역을 사용 권리에 따라 여러 사용자가 시간·지역·수요에 따라 나누어 쓰되, 우선 사용자(incumbent/primary user)의 통신을 보호하는 것이 주파수 공유(spectrum sharing)의 기본 이념이다^[4].

주파수 공유를 실제로 구현하기 위한 초기 기술들은 대체로 규칙 기반(rule-based)으로 설계되었다. 지오로케이션 데이터베이스(geolocation database)에 미리 계산된 보호 규칙을 저장해 두고 이를 조회하거나, 에너지 검출(energy detection)의 고정 임계값으로 대역의 점유 여부를 판정하는 방식이 대표적이다. 이러한 접근은 규칙이 명확하고 검증이 쉽지만, 복잡한 실제 전파 환경에서 간섭을 정확히 예측하기 어렵고 사용자 수와 대역이 늘수록 확장성(scalability)이 급격히 떨어진다. 무엇보다 고정된 규칙은 상정하지 못한 상황에 적응하지 못한다.

이러한 배경에서 최근 주목받는 것이 기계학습(machine learning) 기반의 데이터 주도(data-driven) 접근이다. 신호의 검출·분류, 간섭 예측, 채널·전력 할당을 사람이 설계한 규칙이 아니라 데이터로 학습한 모형으로 수행하여, 불확실하고 동적인 환경에 적응적으로 대응한다는 것이 핵심 착안점이다. 특히 딥러닝(deep learning)과 강화학습(reinforcement learning)의 급속한 발전은 스펙트럼 센싱과 동적 스펙트럼 접속(DSA, dynamic spectrum access)의 성능을 한 단계 끌어올릴 잠재력을 보이고 있으며, 앞서 언급한 IMT-2030의 ‘AI와 통신’ 시나리오와도 맞닿아 있다. [그림 1]은 기계학습 기반 주파수 공유를 표현한 개념도이다.

본 고는 개별 대역이나 응용 시나리오를 깊이 파고드는 대신, 위성 게이트웨이 공유, 상위 6 GHz 대역의 국제이동통신(IMT)과 기존 사용자의 공유, 지상망·비지상망(TN/NTN)



[그림 1] 기계학습 기반 동적 주파수 공유의 개념도 (남색: 1차 사용자, 주황: 2차 사용자, 청록: 학습 흐름)

공유, 레이더 대역 관리, 국방 전술망의 주파수 확보와 같은 여러 응용이 공통으로 딛고 설 수평적 기반 기술로서의 기계 학습과 이를 뒷받침하는 제도적 틀을 총론적으로 정리하는데 목적을 둔다. 이하 본 고에서는 먼저 주파수 공유 기술의 기본 개념과 대표적인 제도·표준을 개론 수준에서 정리(II장)한 뒤, 이를 지능화하는 두 축인 딥러닝 기반 스펙트럼 센싱(III장)과 강화학습 기반 동적 스펙트럼 접속(IV장)의 핵심 기법과 대표 연구를 살펴본다. 이어 연합학습·그래프 신경망·대형 언어모델·디지털 트윈·통합 센싱-통신 등 최신 융합 동향(V장)을 소개하고, 실용화를 위한 도전 과제와 전망(VI장)을 논한 후 결론(VII장)을 맺는다.

II. 주파수 공유 기술 개요

2-1 공유 패러다임의 분류

주파수 공유는 우선 사용자(1차 사용자; PU, primary user)와 인지 사용자(2차 사용자; SU, secondary user)가 하나의 대역을 어떻게 공존시키는가에 따라 크게 세 가지 패러다임으로 구분된다^[4]. 이 분류는 인지무선 기반의 동적 스펙트럼 접속을 다룬 초기 서베이들에서 정립된 것으로, 오늘날 대부분의 공유 시스템을 이해하는 공통 틀이 된다^[5]. 최근에는 이 틀 위에서 인공지능이 동적 스펙트럼 접속을 어떻게 바

꾸고 있는지를 총괄한 개관도 제시되었다^[6].

첫 번째 분류는 언더레이(underlay)로, 2차 사용자가 1차 사용자에게 주는 간섭이 미리 정해진 허용 한계, 즉 간섭 온도(interference temperature) 이하로 유지되는 조건에서 1차 사용자와 동시에 전송하는 것을 말한다. 이 방식에서는 2차 사용자가 항상 낮은 전력으로 넓은 대역에 신호를 펼쳐 1차 사용자의 잡음 마루(noise floor)를 크게 높이지 않도록 해야 하며, 초광대역(UWB, ultra-wideband)이나 확산 스펙트럼(spread spectrum) 기법이 대표적이다. 별도의 스펙트럼 센싱 없이도 동작할 수 있으나, 허용 간섭 한계 때문에 2차 사용자의 전송 거리와 속도가 제한된다. 다만 이 제약 아래에서도 채널 상태가 유리한 2차 송신기를 고르는 기회주의적 스케줄링은 다중 사용자 다이버시티(multi-user diversity) 이득을 준다. 특히 전력을 적응적으로 조절하지 않고 고정 전력으로 전송해도 최적 이득이 달성되어, 1차망과 2차망 사이의 협조 제약과 피드백 오버헤드를 크게 줄일 수 있다^[7].

두 번째 분류는 오버레이(overlay)로, 2차 사용자가 1차 사용자의 신호(메시지·코드북)에 대한 사전 지식을 활용하여 정교한 신호처리와 부호화로 1차 통신 품질을 유지하거나, 오히려 개선하면서 자신의 전송 기회도 확보하는 것을 말한다. 예컨대 2차 사용자가 자신의 전력 일부를 1차 신호의 중계(relay)에 사용해 1차 사용자가 입는 간섭을 상쇄하는 방식이 이에 해당한다. 이론적으로 매력적이나 1차 신호에 대

한 상세한 정보가 필요하여 실현이 까다롭다. 한편 중계 노드를 기회주의적으로 선택하고 간섭 정렬을 결합하여 다중 스트림 전송의 자유도를 확보하는 연구^[8]는 협력적 중계가 간섭 제어의 수단으로 기능할 수 있음을 보인 사례에 해당한다.


세 번째 분류는 인터위브(interweave)로, 2차 사용자가 특정 시간·주파수·공간에서 1차 사용자가 사용하지 않는 자원, 곧 스펙트럼 홀(spectrum hole)을 탐지하여 기회주의적으로 점유하는 것을 말한다. 스펙트럼 홀은 시간축(특정 시각에 비어 있음)·주파수축(특정 채널이 비어 있음)·공간축(특정 지역에서 비어 있음)에서 나타날 수 있으며, 이 기회주의적 접속(opportunistic spectrum access)이 바로 동적 스펙트럼 접속(DSA)의 원형이다. 인터위브는 정확한 스펙트럼 센싱을 전제로 하므로 센싱 성능이 곧 공유 효율을 좌우한다.

이 세 패러다임은 상호 배타적이지 않아 실제 시스템에서는 혼합되어 쓰인다. 또한 자원 배정의 시간 척도(time scale)에 따라, 고정된 배타 할당을 장기간 유지하는 정적 공유와 시간·지역·수요에 따라 실시간으로 자원을 재배정하는 동적 공유로 나뉜다. 정적 공유는 관리가 단순한 대신 이용 효율이 낮고, 동적 공유는 그 반대다. 어느 쪽이든 공유의 성패는 결국 사용자들 사이의 간섭을 얼마나 정교하게 다루는가에 달려 있다. 다중 셀·다중 안테나 환경에서 기회주의적 사용자 스케줄링과 간섭 정렬(interference alignment)을 결합해 자유도를 확보하는 기법^{[9],[10]}, 동적 시분할 이중화(dynamic TDD)의 교차 간섭을 국소 채널 정보만으로 분산 정렬하는 기법^[11], 포그 무선접속망에서 단말별 안테나 수에 맞추어 간섭 차원을 조정하는 협조 기법^[12], 협조 빔포밍과 간섭 인지 전력 제어·스케줄링을 결합한 프레임워크^[13] 등이 그 예이며, 이러한 모형 기반 간섭 관리 기법은 학습 기반 공유 기법이 성능을 견주는 기준선을 이룬다. [그림 2]는 이러한 분류 체계를 정리한 것이다.


2.2 인지무선과 스펙트럼 센싱

동적 공유의 이론적 토대는 인지무선(cognitive radio) 개념에서 출발한다. Mitola와 Maguire는 소프트웨어 정의 라디오(SDR, software-defined radio)의 확장으로서 주변 전파 환경을 인지하고 스스로 동작 파라미터를 조정하는 무선기기를 인지무선이라 명명하였다^[14]. 이후 Haykin은 이를 신호처

리 관점에서 정련하여, 인지무선의 세 가지 핵심 과업을 (1) 전파 환경 분석(radio-scene analysis), (2) 채널 상태 추정 및 예측 모델링, (3) 송신 전력 제어와 동적 스펙트럼 관리로 정리하였다^[15]. 이 세 과업은 [그림 3]과 같이 '관찰(observe) - 분석(analyze) - 결정(decide) - 행동(act)'으로 이어지는 인지 사이클(cognitive cycle)을 이루며, 무선기기는 이 순환을



[그림 2] 주파수 공유 패러다임의 분류



[그림 3] 인지무선의 인지 사이클 (관찰 - 분석 - 결정 - 행동)

반복하면서 환경 변화에 스스로 적응한다. 뒤에서 살펴볼 학습 기반 기법들은 이 사이클의 각 단계를 학습한 모형으로 대체·강화하는 시도로 볼 수 있다.

인지 사이클의 출발점이 스펙트럼 센싱이다. 고전적 센싱 기법은 크게 세 가지로 나뉘며, 각각 뚜렷한 장단점을 지닌다^[16]. 첫째, 에너지 검출(energy detection)은 수신 신호의 에너지를 임계값과 비교한다. 사전 정보가 필요 없고 구현이 단순하나, 잡음 전력의 불확실성(noise uncertainty)에 취약하여 낮은 신호대잡음비(SNR)에서는 관측 시간을 늘려도 검출이 보장되지 않는 이른바 'SNR 장벽(SNR wall)'이 존재하고, 신호와 간섭을 구분하지 못한다. 둘째, 정합 필터(matched filter)는 파일럿·프리앰블 등 알려진 신호 구조와의 상관을 이용하는 최적 검출기로 짧은 관측 시간에 목표 성능을 달성하지만, 1차 신호의 변조·펄스 형상·동기 정보를 알아야 하고 신호마다 전용 수신기가 필요하다. 셋째, 순환정상성 검출(cyclostationary feature detection)은 신호의 주기적 통계 특성을 이용해 정상성을 띠는 잡음과 신호를 구분한다. 저 SNR에 강건하고 신호 유형까지 식별하지만 연산 복잡도가 높고 긴 관측 시간을 요구한다. 이처럼 고전적 기법은 정확도·복잡도·사전 지식 사이의 상충을 안고 있으며, 이 한계가 학습 기반 센싱(III장)의 동기가 된다.

2.3 대표적 주파수 공유 제도와 표준

주파수 공유는 학술적 개념에 머무르지 않고 이미 여러 나라에서 제도와 표준으로 구현되어 운용되고 있다. 대표적 사례를 차례로 상술하고 <표 1>에 요약한다.


먼저 미국의 CBRS(citizens broadband radio service)는 미국 연방통신위원회(FCC)가 2015년 규정 47 CFR Part 96을 통해 수립하고 2020년 초 상용화한 제도로, 3.55~3.70 GHz의 150 MHz 대역을 3계층으로 공유한다. 최상위 계층인 기존 사용자(incumbent access)는 연방 해군 레이더와 고정위성 서비스(FSS) 지구국을 최우선 보호하고, 중간 계층인 우선 접속 면허(PAL, priority access license)는 3.55~3.65 GHz에서 10 MHz씩 7개를 인구조사 구역 단위로 경매 할당하며, 최하위 계층인 일반 인가 접속(GAA, general authorized access)은 상위 계층에 간섭을 주지 않는 조건으로 대역 전체를 개방한다. 이 계층적 공유를 실시간으로 조정하는 핵심 요소가 클라우드 기반 데이터베이스인 스펙트럼 접속 시스템

<표 1> 대표적 주파수 공유 제도·표준 비교

제도/표준	대역	공유 방식	관리 주체·핵심 요소
CBRS (미국)	3.55~3.70 GHz	3계층(Incumbent/PAL/GAA)	SAS(클라우드 DB) + ESC(센싱)
AFC (미국)	6 GHz U-NII-5/7	DB 기반 자동 조정	AFC 시스템, P2P 링크 보호
LSA/ASA (유럽)	2.3 GHz 등	면허 기반 공유	LSA 리포지토리 + 컨트롤러
3GPP DSS	LTE/NR 대역	동일 반송파 시분할 공유	기지국 스케줄러
IEEE 802.22	TV 대역 (54~862 MHz)	인지무선 (DB+센싱)	지오로케이션 DB
한국 (K-AFC 등)	6 GHz 등	공동사용·민군공유	과기정통부, 한국형 AFC

(SAS, spectrum access system)으로, 각 기기의 등록·주파수 배정·송신 전력을 동적으로 관리한다. 여기에 더해 연안의 환경 센싱 기능(ESC, environmental sensing capability)이 연방 레이더를 탐지해 SAS에 통보하면, SAS는 보호 구역을 활성화하고 기기를 인접 채널로 재배치한다. 기기(CBSD)는 저 출력 Category A와 실외 전용 고출력 Category B로 구분된다. CBRS는 이처럼 규칙 기반 데이터베이스(SAS)와 물리적 센싱(ESC)을 결합한 대표적 사례이며, [그림 4]에 그 구조를 도식화하였다^[17].

다음으로 6 GHz AFC(automated frequency coordination)는 6 GHz 비면허(U-NII, unlicensed national information infrast-



[그림 4] CBRS 3계층 공유와 SAS-ESC 기반 동적 조정 구조

ructure) 대역 중 U-NII-5(5.925~6.425 GHz)와 U-NII-7(6.525~6.875 GHz)에서 표준 전력(standard-power) 액세스포인트가 기존 고정 점대점(point-to-point) 마이크로웨이브 링크를 보호하도록, 위치 기반으로 가용 채널과 출력을 산출해 주는 자동 주파수 조정 시스템이다. 표준 전력 액세스포인트의 최대 등가등방복사전력(EIRP)은 36 dBm이며, FCC는 2024년 초 다수의 AFC 시스템 운용을 승인하였다. AFC는 CBRs의 SAS와 유사하게 데이터베이스가 실시간으로 공유를 중재하는 구조를 취한다^[18].

유럽의 LSA/ASA(licensed/authorised shared access)는 이미 할당되었으나 저활용되는 대역을 기존 사용자와 이동통신 사업자가 합의된 주파수·위치·시간 조건에서 면허 기반으로 공유하는 방식이다. 초기 타깃 대역은 2.3 GHz(2,300~2,400 MHz)이며, 가용 자원 정보를 담은 LSA 리포지토리와 사업자 도메인에서 이를 준수하는 LSA 컨트롤러로 구성된다. 유럽전기통신표준협회(ETSI)가 TS 103 154, TS 103 235, TS 103 379 등으로 표준화하였다^[19].

3GPP의 DSS(dynamic spectrum sharing)는 LTE와 5G NR이 동일한 반송파·대역을 동시에 사용하도록 하여, 미사용 LTE 자원 위에 NR 신호를 전송함으로써 LTE에서 NR로의 점진적 마이그레이션을 지원하는 기술이다. 기존 대역을 재사용하므로 신규 대역 없이도 5G를 조기 도입할 수 있어, Release 15에 도입되어 이후 릴리스에서 확장되었다^[20].

TV 화이트 스페이스(TVWS)는 TV 방송 대역(대략 54~862 MHz)의 미사용 구간을 인지무선으로 활용하는 방식으로, IEEE 802.22 WRAN 표준은 지오로케이션 데이터베이스와 스펙트럼 센싱을 병용하여 최대 수십 km 규모의 농어촌 광대역 접속을 목표로 하였다. TV 대역은 전파 도달 거리가 길어 광역 서비스에 유리하다는 점에서 초기 동적 공유의 대표적 시험대가 되었다^[21].

끝으로 국내에서는 과학기술정보통신부가 「대한민국 스펙트럼 계획(‘24~’27년)」을 통해 시간·지역·공간적 주파수 공동사용의 확대, 민·군 공동사용, 그리고 6 GHz 대역 Wi-Fi 등을 위한 한국형 자동 주파수 조정 체계의 도입을 추진하고 있다^[22].

이상의 제도들은 대부분 규칙 기반 데이터베이스와 고정 임계값 센싱에 의존한다. 앞서 언급한 여러 응용은 이러한

공유 패러다임과 제도가 특정 대역·운용 환경에 맞추어 구체화된 사례에 해당한다. 한편, 주파수 공유는 기술만으로 완성되지 않으며, 우선 사용자가 자신의 대역을 개방하도록 유도하는 규제·경제적 유인 기제가 함께 요구된다. CBRs의 PAL 경매가 대표적이며, 사용권을 거래하는 2차 스펙트럼 시장(secondary market)이나 대역을 양보하는 기존 사용자에게 보상하는 인센티브 공유(incentive-based sharing) 등이 논의된다. 즉 효율적 공유는 규칙 기반 제도, 학습 기반 지능화, 그리고 경제적 유인이라는 세 축이 맞물릴 때 실현된다. 다음 장부터는 이러한 제도적 토대 위에서 센싱과 접속을 학습 기반으로 지능화하는 최신 흐름을 살펴본다.

III. 딥러닝 기반 스펙트럼 센싱

스펙트럼 센싱의 본질은 수신 신호로부터 특정 대역의 점유 여부(또는 신호의 종류)를 판정하는 검출·분류 문제이다. 앞서 살펴본 고전적 기법이 사람이 설계한 통계량(에너지, 상관, 순환 주파수 등)에 의존하는 반면, 딥러닝 기반 센싱은 원시 동위상/직교(IQ) 표본이나 공분산 행렬, 스펙트로그램 등에서 판별에 유용한 특징을 자동으로 학습한다. 어떤 통계량을 쓸지 미리 정하지 않아도 되고, 잡음 불확실성·저 SNR·다중경로 페이딩처럼 명시적 모델링이 어려운 조건에서도 강인하다는 점이 학습 기반 접근의 매력이다.

3-1 자동 변조 인식

딥러닝 센싱의 대표적 성공 사례는 자동 변조 인식(AMC, automatic modulation classification)이다. 변조 방식 식별은 검출된 신호가 보호해야 할 우선 사용자의 것인지 다른 간섭 원인지를 구분하게 해 주므로 주파수 공유에서 중요하다. O'Shea 등은 복소 시계열 IQ 신호를 두 개(실수부·허수부)의 채널로 두고 합성곱 신경망(CNN)에 직접 입력하여, 전문가가 고차 통계량 등으로 설계한 특징 기반 분류기보다 특히 저 SNR 영역에서 우수한 인식 성능을 얻을 수 있음을 보였다^[23]. 이는 사람이 특징을 설계하는 대신, 원시 신호로부터 종단간(end-to-end)으로 특징과 분류를 함께 학습한 결과이다. 이 연구에서 공개된 RadioML 계열 데이터셋은 이후

이 분야의 사실상 표준 벤치마크가 되었다. 후속 연구는 반송파 주파수 오프셋·심볼율 변동·다중경로 페이딩을 포함한 실제 무선(over-the-air) 환경에서 잔차망(ResNet) 계열 구조를 분석하여, 딥러닝 기반 분류가 고 SNR에서 높은 정확도로 포화하고 저 SNR에서 전통 기법 대비 이득을 가짐을 보였다^[24]. 이후로도 저 SNR 영역의 강인성을 높이기 위한 구조 탐색이 이어져, 합성곱과 선행 어텐션을 계층적 트랜스포머로 결합한 하이브리드 구조가 제안되어 신호가 지닌 다양한 특징을 폭넓게 활용함으로써 낮은 SNR에서도 안정적인 인식 성능을 보고하였다^[25].


3-2 협력 센싱과 신경망 구조

단일 센서의 관측은 음영(shadowing)과 페이딩에 취약하므로, 여러 2차 사용자의 센싱 결과를 결합하는 협력 센싱(cooperative sensing)이 널리 사용된다. 융합 방식은 이진 판정을 다수결·논리합 등으로 합치는 경성 결합(hard combining)과, 연속적 검정 통계량을 그대로 모으는 연성 결합(soft combining)으로 나뉜다. 경성 결합은 제어 채널 부담이 작지만 정보 손실이 있고, 연성 결합은 성능이 우수하지만 오버헤드가 크다. 전통적으로는 이러한 융합을 사람이 설계한 규칙(우도비 결합 등)으로 수행하였으나, 근래에는 융합 전략 자체를 신경망으로 학습하는 접근이 자리를 잡았다. Fang 등은 사용자별 특징을 따로 뽑아 합치는 기존 딥러닝 방식이 사용자 사이의 상관을 활용하지 못한다는 점에 주목하여, 합성곱 계층과 트랜스포머를 결합해 사용자 내부와 사용자 간 상관을 함께 포착하는 사후 확률비 검출기를 제안하고, 보고 채널이 불완전한 조건에서도 전통적 에너지 검출 대비 약 6 dB의 이득을 보고하였다^[26]. 같은 맥락에서 어텐션 기반 분기와 합성곱 분기가 뽑아낸 특징을 결합하는 다중 분기 신경망으로 협력 센싱의 판정 정확도를 높인 연구도 보고되었다^[27].

신경망 구조로는 국소 패턴을 포착하는 CNN, 시간적 상관을 모델링하는 순환 신경망(RNN)·장단기 기억(LSTM), 장거리 의존성을 자기어텐션으로 포착하는 트랜스포머(transformer) 계열이 활용된다. 예컨대 Shao 등은 원시 IQ 신호와 시간-주파수 변환 행렬을 함께 입력받아 두 양식(modality)의 특징을 융합하고, 합성곱과 어텐션을 결합한 트


랜스포머 블록으로 국소·전역 특징을 함께 추출하여 낮은 SNR에서 기존 기법을 능가함을 보였다^[28]. 입력 표현 또한 원시 IQ, 진폭·위상, 스펙트로그램, 공분산 행렬 등으로 다양하다. 최근의 한 메타분석은 스펙트럼 센싱에 적용된 기계학습·딥러닝 연구를 서베이와 1차 연구에 걸쳐 종합하여, 주요 신경망 구조와 성능 지표를 정리하는 한편, 계산 복잡도·실시간 적응·일반화를 남은 과제로 지목하였다^[29]. 나아가 협력 센싱을 판별형 딥러닝, 생성 모델, 강화학습의 세 갈래로 나누어 정리하고 시맨틱 통신을 새로운 축으로 조망한 서베어도 제시되었다^[16]. [그림 5]는 딥러닝 기반 스펙트럼 센싱의 전형적 처리 흐름을 도식화한 것이다.

IV. 강화학습 기반 동적 스펙트럼 접속



[그림 5] 딥러닝 기반 스펙트럼 센싱의 처리 흐름
(IQ 입력 → 특징 학습 → 점유/변조 판정)

스펙트럼 센싱이 '지금 이 대역이 비어 있는가'를 판정하는 문제라면, 동적 스펙트럼 접속(DSA)은 '어느 채널에, 어느 전력으로 접속할 것인가'를 시간에 걸쳐 결정하는 순차적 의사결정 문제이다. 채널의 점유 상태가 미지이고 시간에 따라 변하며, 다른 사용자의 행동에 의해 환경이 바뀌는 상황에서는 시스템의 동역학 모델을 미리 알기 어렵다. 이러한 문제는 마르코프 결정과정(MDP, Markov decision process)으로 정식화되는데, 여기서 상태(state)는 관측된 채널 점유 이력이나 센싱 결과에, 행동(action)은 접속할 채널과 전력의 선택에, 보상(reward)은 성공적 전송(및 우선 사용자에 대한 간섭 위반 시의 페널티)에 각각 대응한다. 실제로 2차 사용자는 전체 채널을 동시에 관측하지 못하므로 부분 관측 MDP(POMDP)로 모델링되며, 다중 슬롯머신(restless multi-armed bandit) 문제와도 연결된다. 강화학습은 환경과의 상호작용과 시행착오로 누적 보상을 최대화하는 정책을 학습하는 모델-프리(model-free) 방법이어서 이러한 문제에 특히 적합하다. [그림 6]은 DSA를 강화학습 문제로 정식화한 에이전트-환경 상호작용 구조를 보인다.



[그림 6] 강화학습 기반 동적 스펙트럼 접속 프레임워크
(상태·행동·보상)

4.1 심층 Q 신경망 기반 채널 접속

상태 공간이 큰 문제에서는 각 상태-행동 쌍의 가치를 나타내는 Q 값을 표로 저장하는 대신, 심층 신경망으로 근사하는 심층 Q 신경망(DQN, deep Q-network)이 효과적이다. DQN은 학습 안정화를 위해 과거 경험을 무작위로 재사용해 시간적 상관을 줄이는 경험 재현(experience replay)과 목표 Q 값 계산에 쓰는 파라미터를 지연 갱신하는 타깃 네트워크(target network)를 쓴다. 다만 부분관측 환경에서는 관측 이력을 요약하는 순환 구조가 함께 요구된다. 최근에는 저장형 순환망(echo state network)으로 환경 모형을 학습하고 그로부터 생성한 가상 경험으로 정책을 갱신하여, 실제 상호작용 횟수를 크게 줄이면서도 접속 성능을 확보하는 표본 효율적 기법이 제안되었다^[30]. 여러 사용자가 함께 학습하는 환경으로 확장하여, 관측 범위와 송신 전력, 유휴 채널의 집성 능력이 서로 다른 이질적 2차 사용자가 공존하는 인지 무선망에서 에이전트별로 다른 정책을 학습시키는 기법도 제시되었다^[31]. 나아가 심층 강화학습 기반 접속이 어떤 조건에서 수렴하는지를 이론적으로 분석하고 시스템 설계 지침을 도출하려는 연구가 이어져, 실제 시스템 적용의 근거가 축적되고 있다^[32].

4.2 분산·다중 에이전트 접속과 전력 제어

실제 무선망에서는 다수의 사용자가 중앙 조정 없이 분산적으로 채널을 선택하며, 각자가 부분적으로만 환경을 관측한다. 초기 연구가 채널의 완전 직교를 가정한 것과 달리, Cohen 등은 인접 반송파 간섭과 채널 재사용이 존재하는 인지 간섭망에서 중앙 집중 학습·분산 실행(CTDE, centralized training with decentralized execution) 방식의 다중 에이전트 강화학습을 제안하여, 저차원 관측만으로 서비스 품질을 지키면서 전역 신호 대 간섭·잡음비(SINR)를 최대화하고 완전 중앙 집중 방식에 근접하는 성능을 얻었다^[33]. 한편, 채널 선택을 넘어 전력 제어까지 확장한 연구로, Zhang과 Guo는 다중 셀 환경에서 각 기지국이 국소 정보만으로 사용할 스펙트럼과 송신 전력을 함께 결정하는 다중 에이전트 강화학습 기법을 제안하였다^[34]. 다만 다중 에이전트 환경에서는 각 에이전트의 정책 변화가 다른 에이전트에게 환경의 비정상성(non-stationarity)으로 작용하므로, 이를 완화하는 학습 안

정화가 중요한 과제로 남는다. 한편, 분산 학습은 망 전체가 점유하는 주파수 폭 자체를 줄이는 문제로도 확장된다. 각 링크의 서비스 품질을 보장하면서 사용 주파수의 최대·최소 차이, 곧 스패(span)를 최소화하는 최소 스패 주파수 할당 문제는 본래 중앙 집중적 조합 최적화 문제로서, 부분 중첩 채널과 물리 간섭 모형을 고려한 정수계획 기반 최적해와 저복잡도 휴리스틱^[35], 이를 벡터 빈 패킹(vector bin packing)으로 정식화한 해법^[36]이 제안되었다. 그러나 무인기(UAV) 망처럼 위상이 실시간으로 변하면 중앙 제어기가 전역 정보를 모으기 어렵다. 이에 각 노드가 국소 관측만으로 채널을 고르도록 다중 에이전트 Q-학습을 적용하여 분산적으로 스패를 줄이는 기법^[37]과, 주파수 재사용률과 송신 전력을 계층적 다중 에이전트 강화학습으로 함께 최적화하여 에너지 효율을 높이는 기법^[38]이 보고되었다. 무선 스펙트럼 관리에 다중 에이전트 심층 강화학습을 적용한 사례들은 최근 별도의 서베어로 폭넓게 정리되어 있어, 채널 할당·접속 제어·전력 관리 등 다양한 문제에 걸쳐 그 유용성이 확인되고 있다^[39].

4.3 우선 사용자 보호와 안전한 학습

주파수 공유에서 강화학습을 적용할 때 반드시 지켜야 할 제약은 우선 사용자에게 대한 보호이다. 순수한 시행착오 학습은 탐색(exploration) 과정에서 우선 사용자에게 허용치를 넘는 간섭을 유발할 수 있어 규제적으로 용인되기 어렵다. 이를 위해 간섭 위반에 큰 페널티를 부여하도록 보상을 설계하거나, 누적 간섭·충돌 확률과 같은 제약 함수를 임계값 이하로 유지하도록 문제를 제약 마르코프 결정과정(constrained MDP)으로 정식화하는 안전 강화학습(safe reinforcement learning) 기법이 연구되고 있다. 예컨대 최근의 6G 스펙트럼 슬라이싱 연구는 셀 간 간섭 예산과 지연 요구를 명시적 제약으로 두고, 라그랑주 프라이멀-듀얼 기법과 근접 정책 최적화(PPO)를 결합하여 제약을 만족시키면서 스펙트럼 효율을 최대화하는 다중 에이전트 정책을 학습하였다^[40]. 이는 보상 최대화와 규제 준수를 동시에 달성하려는 시도로, 학습 기반 기법을 실제 공유에 도입하기 위한 전제 조건이다. 또한 채널 선택·전력 제어·변조 선택을 하나의 정책으로 결합 최적화하려는 시도가 이어져, 센싱(III장)과

접속(IV장)이 단일 학습 루프로 통합되고 있다. <표 2>는 이상에서 살펴본 딥러닝 센싱과 강화학습 접속의 대표 연구를 정리한 것이다.

V. 최신 융합 동향

딥러닝 센싱과 강화학습 접속을 두 축으로, 최근에는 이를 보완·확장하는 다양한 융합 기술이 활발히 연구되고 있다.

첫째, 연합학습(federated learning) 기반 협력 센싱은 각 사용자가 수집한 원시 신호를 중앙 서버로 전송하지 않고 로컬에서 학습한 모델 갱신값만 공유·집계함으로써, 프라이버시를 보호하고 통신 부하를 줄이면서 협력 센싱 모델을 학습한다. 이는 McMahan 등이 제안한 연합 평균화(FedAvg) 알고리즘^[41]에 기반하며, 최근에는 사용자마다 관측하는 특징이 서로 다른 상황을 다루는 온라인 수직 연합학습이 협력 스펙트럼 센싱에 적용되어, 원시 신호를 공유하지 않고도 검출 성능과 통신 효율을 함께 확보할 수 있음이 보고되었다^[42].

둘째, 그래프 신경망(GNN)은 무선망을 노드(송수신기)와

<표 2> 학습 기반 주파수 공유의 대표 연구

구분	대표 연구	핵심 기법	주요 기여
DL 센싱	O'Shea 등 ^[23] , ^[24]	CNN · ResNet, 원시 IQ 입력	자동 변조 인식, RadioML 벤치마크
DL 센싱	Shao 등 ^[28]	다중 모달리티 융합 트랜스포머	저 SNR 변조 인식 성능 개선
DL 센싱	Fang 등 ^[26]	CNN-트랜스포머 협력 센싱	사용자 간 상관 활용, 융합 규칙 대체
RL 접속	Chang 등 ^[30]	Dyna-ESN (모형 기반 DRL)	부분관측 DSA 표본 효율 개선
RL 접속	Cohen 등 ^[33]	다중 에이전트 DRL(CTDE)	SINR 인지 분산 채널 할당
RL 접속	Zhang · Guo ^[34]	다중 에이전트 DRL	다중 셀 스펙트럼 · 전력 할당
RL 접속	Lee 등 ^[37] , ^[38]	다중 에이전트 Q-학습	분산 최소 스패 채널 할당, 주파수 재사용 · 전력 제어
RL 접속	Mohammadi 등 ^[40]	제약 MDP + 연합 DRL	간섭 예산 제약 하, 안전한 학습

간선(간접 관계)의 그래프로 모델링하며, 순열 불변성(permutation invariance) 덕분에 사용자 수 변화에 강인하고 확장성 좋은 자원 할당 정책을 학습할 수 있다. Shen 등은 무선 자원 관리 문제를 그래프 최적화 문제로 정식화하고, GNN이 갖는 순열 등변성과 일반화 능력에 대한 이론적 근거를 실제 설계 지침과 함께 제시하여, 그래프 구조를 활용한 학습이 대규모 네트워크에서도 잘 일반화됨을 보였다^[43]. 최근에는 다중 셀 통합 센싱-통신 환경의 협력 빔포밍을 표적 중심 그래프로 모델링하고 그래프 신경망으로 빔포밍 정책을 학습하여, 통신 품질을 지키면서 표적 탐지 확률을 최대화한 연구가 제시되었다^[44]. 그래프 기반 학습이 간섭 관리와 센싱을 함께 다루는 데까지 확장되고있는 것이다.

셋째, 대형 언어모델(LLM)·트랜스포머 기반의 관리 기법이다. 최근에는 대형 언어모델을 활용하여 자연어로 기술된 네트워크 운용 목표를 문제로 정식화하고 스펙트럼 관리 정책을 자동 생성하려는 시도가 등장하고 있다^[45]. 다만 스펙트럼 공유에 대한 직접 적용은 아직 초기 단계로, 신뢰성과 검증이 관건이다.

넷째, 디지털 트윈(digital twin)은 전파 환경을 가상 공간에 실시간으로 복제해 채널과 간섭을 예측하고, 선제적 간섭 완화와 전송 기회 최대화를 도모한다. 위성-지상 통합망의 동적 공유 등에서 활용이 모색되나 아직 초기 단계이며, 전파 환경에 관한 지식을 체계적으로 축적하여 6G 디지털 트윈 채널을 구성하고 이로부터 채널을 복제·예측하는 구조가 제시되었다^[46].

끝으로 통합 센싱-통신(ISAC)은 통신과 레이더 센싱이 스펙트럼과 하드웨어, 나아가 하나의 이중 기능(dual-functional) 파형을 공유하는 시스템으로, 앞서 언급한 IMT-2030의 6대 이용 시나리오 중 하나로 채택되며 6G의 핵심 기술로 부상하고 있다^[47]. ISAC은 센싱이 곧 실시간 스펙트럼 상황 인지를 제공하므로 동적 공유의 데이터 원천으로 자연스럽게 결합되며, 레이더 대역의 효율적 이용과도 맞닿아 있다. 최근에는 여기에 인공지능을 접목한 지능형 ISAC(intelligent ISAC)이 별도의 연구 흐름으로 정리되고 있다^[48].

이처럼 융합 기술은 학습 기반 센싱과 접속이라는 두 축을 분산화·예측·통합의 방향으로 확장하지만, 실용화에 이르기까지는 공통된 도전 과제가 남아 있다.

VI. 도전 과제 및 전망

기계학습 기반 주파수 공유가 실용화되기까지 해결해야 할 과제는 여전히 많다.

첫째, 데이터셋과 일반화이다. RadioML 등 일부를 제외하면 표준 벤치마크가 부족해 공정한 비교가 어렵고, 시물레이션으로 학습한 모델이 실제 환경에서 겪는 도메인 격차(domain gap) 때문에 전이 학습이나 도메인 적응이 요구된다. 둘째, 적대적 강인성과 보안이다. 학습 기반 센싱·접속은 입력에 미세한 교란을 더해 오판을 유도하는 스펙트럼 적대 공격(adversarial attack)에 취약할 수 있으며, 연합학습은 악의적 참여자가 잘못된 갱신값을 주입하는 오염(poisoning) 공격의 위험을 안는다. 셋째, 분산 학습의 수렴이다. 다중 에이전트 환경에서는 각 에이전트의 학습이 서로에게 비정상적 환경을 만들어 수렴을 어렵게 하므로 안정화 기법이 필요하다. 넷째, 설명 가능성과 규제 신뢰이다. SAS·AFC처럼 우선 사용자 보호가 법적 의무인 시스템에 블랙박스 인공지능을 도입하려면 결정의 근거를 검증하고 안전을 보장할 수 있어야 한다. 다섯째, 실시간성과 표준화이다. 엣지 단말의 제한된 자원에서 낮은 지연으로 추론해야 하므로 모델 경량화가 요구되며, 3GPP·ETSI·FCC의 규칙 체계와 학습 기반 기법을 정합시키는 노력이 병행되어야 한다.

그럼에도 불구하고 방향은 분명하다. 규칙 기반 공유(CBRS·AFC·LSA·DSS)가 닦아 놓은 제도적 토대 위에서, 딥러닝 센싱과 강화학습 접속이 상황 인지와 의사결정의 정확도를 높이고, 연합학습·GNN·LLM·디지털 트윈·ISAC이 이를 분산적이고 예측적이며 통합적인 형태로 확장하는 흐름이다. 이러한 데이터 주도 지능화는 한정된 주파수 자원의 이용 효율과 서로 다른 시스템 간 공존 능력을 동시에 끌어올리는 핵심 수단이 될 것이다.

VII. 결 론

본 고에서는 주파수 공유의 기본 개념과 대표 제도를 정리하고, 이를 지능화하는 기계학습 기반 기술의 최신 동향을 딥러닝 스펙트럼 센싱과 강화학습 동적 스펙트럼 접속을

중심으로 살펴보았다. 나아가 연합학습·그래프 신경망·대형 언어모델·디지털 트윈·통합 센싱-통신 등 융합 동향과 실용화 과제를 논하였다. 주파수 공유는 이제 고정된 규칙에 따라 대역을 나누는 단계를 넘어, 전파 환경을 학습하고 예측하여 스스로 자원을 배분하는 데이터 주도 지능화의 단계로 진입하고 있다. 우선 사용자 보호라는 규제적 제약과 학습 기반 기법의 유연성을 조화시키는 연구가 성숙함에 따라, 기계학습 기반 동적 주파수 공유는 6G 시대의 스펙트럼 부족 문제를 완화하는 실질적 해법으로 자리매김할 것으로 전망된다.

참 고 문 헌

- [1] Ericsson, "Ericsson Mobility Report." Ericsson, Stockholm, Sweden, Nov. 2024.
- [2] ITU-R, "Recommendation ITU-R M.2160-0: Framework and overall objectives of the future development of IMT for 2030 and beyond," Nov. 2023.
- [3] A. Bazzi et al., "Upper mid-band spectrum for 6G: Vision, opportunity and challenges," *IEEE Communications Magazine*, vol. 64, no. 1, pp. 206-212, Jan. 2026.
- [4] S. K. Jagatheesaperumal et al., "Deep learning frameworks for cognitive radio networks: Review and open research challenges," *Journal of Network and Computer Applications*, vol. 233, art. no. 104051, Jan. 2025.
- [5] I. F. Akyildiz et al., "NeXt generation/dynamic spectrum access/cognitive radio wireless networks: A survey," *Computer Networks*, vol. 50, no. 13, pp. 2127-2159, Sep. 2006.
- [6] A. Gbenga-Ilori et al., "Artificial intelligence empowering dynamic spectrum access in advanced wireless communications: A comprehensive overview," *AI*, vol. 6, no. 6, art. no. 126, Jun. 2025.
- [7] T.-W. Ban and B. C. Jung, "On the multi-user diversity with fixed power transmission in cognitive radio networks," *IEEE Wireless Communications Letters*, vol. 3, no. 1, pp. 74-77, Feb. 2014.
- [8] H. Lin, W.-Y. Shin, and B. C. Jung, "Multi-stream opportunistic network decoupling: Relay selection and interference management," *IEEE Transactions on Mobile Computing*, vol. 18, no. 10, pp. 2372-2385, Oct. 2019.
- [9] B. C. Jung, D. Park, and W.-Y. Shin, "Opportunistic interference mitigation achieves optimal degrees-of-freedom in wireless multi-cell uplink networks," *IEEE Transactions on Communications*, vol. 60, no. 7, pp. 1935-1944, Jul. 2012.
- [10] H. J. Yang, W.-Y. Shin, B. C. Jung, C. Suh, and A. Paulraj, "Opportunistic downlink interference alignment for multi-cell MIMO networks," *IEEE Transactions on Wireless Communications*, vol. 16, no. 3, pp. 1533-1548, Mar. 2017.
- [11] K. S. Ko, B. C. Jung, and M. Hoh, "Distributed interference alignment for multi-antenna cellular networks with dynamic time division duplex," *IEEE Communications Letters*, vol. 22, no. 4, pp. 792-795, Apr. 2018.
- [12] S.-W. Jeon, B. C. Jung, H. Lee, and J. Park, "Interference coordination for heterogeneous users in asynchronous fog radio access networks," *IEEE Wireless Communications Letters*, vol. 8, no. 4, pp. 1064-1068, Aug. 2019.
- [13] Y. Kim, B. C. Jung, and Y. Han, "Coordinated beamforming, interference-aware power control, and scheduling framework for 6G wireless networks," *Journal of Communications and Networks*, vol. 24, no. 3, pp. 292-304, Jun. 2022.
- [14] J. Mitola and G. Q. Maguire, "Cognitive radio: Making software radios more personal," *IEEE Personal Communications*, vol. 6, no. 4, pp. 13-18, Aug. 1999.
- [15] S. Haykin, "Cognitive radio: Brain-empowered wireless communications," *IEEE Journal on Selected Areas in Communications*, vol. 23, no. 2, pp. 201-220, Feb. 2005.
- [16] P. Yi and Y.-C. Liang, "Collaborative spectrum sensing in cognitive and intelligent wireless networks: An artificial intelligence perspective," *arXiv*, arXiv:2602.09615, 2026.
- [17] Federal Communications Commission, "47 CFR Part 96: Citizens Broadband Radio Service."
- [18] Federal Communications Commission, "OET approves

- AFC systems for the 6 GHz band,” DA-24-166, 2024.
- [19] ETSI, “Licensed Shared Access (LSA),” TS 103 154/235/379, 2017.
- [20] 3GPP, “NR and E-UTRA dynamic spectrum sharing (DSS),” 3rd Generation Partnership Project (3GPP), Release 15, 2018.
- [21] IEEE Std 802.22-2011, “Wireless regional area networks (WRAN) – Part 22,” 2011.
- [22] 과학기술정보통신부, “대한민국 스펙트럼 계획(24~27년) 발표,” 보도자료, 2024.
- [23] T. J. O’Shea et al., “Convolutional radio modulation recognition networks,” in *Proceedings of Int. Conf. Eng. Appl. Neural Netw. (EANN)*, pp. 213-226, 2016.
- [24] T. J. O’Shea et al., “Over-the-air deep learning based radio signal classification,” *IEEE J. Sel. Topics Signal Process.*, vol. 12, no. 1, pp. 168-179, Feb. 2018.
- [25] J. Zhao et al., “MILAFormer: A multi-stage hybrid deep learning architecture for robust radio signal modulation recognition,” *IEEE Trans. Cogn. Commun. Netw.*, vol. 12, pp. 7574-7588, 2026.
- [26] X. Fang et al., “CNN-transformer-based cooperative spectrum sensing in cognitive radio networks,” *IEEE Wireless Commun. Lett.*, vol. 14, no. 5, pp. 1576-1580, May 2025.
- [27] D. T. Lan et al., “A multi-branch network for cooperative spectrum sensing via attention-based and CNN feature fusion,” *Sci. Rep.*, vol. 16, art. no. 5111, Jan. 2026.
- [28] M. Shao et al., “IQFormer: A novel transformer-based model with multi-modality fusion for automatic modulation recognition,” *IEEE Trans. Cogn. Commun. Netw.*, vol. 11, no. 3, pp. 1623-1634, Jun. 2025.
- [29] M. Falco et al., “AI-driven spectrum sensing: An in-depth meta-analysis of trends, challenges and opportunities,” *Comput. Netw.*, vol. 275, art. no. 111789, Feb. 2026.
- [30] H.-H. Chang et al., “Dyna-ESN: Efficient deep reinforcement learning for partially observable dynamic spectrum access,” *IEEE Trans. Wireless Commun.*, vol. 24, no. 6, pp. 4517-4531, Jun. 2025.
- [31] Q. Wang et al., “A heterogeneous-agent deep reinforcement learning approach for dynamic spectrum access in cognitive wireless networks,” *IEEE Trans. Cogn. Commun. Netw.*, vol. 12, pp. 2221-2235, 2026.
- [32] R. Safavinejad et al., “Deep reinforcement learning for dynamic spectrum access: Convergence analysis and system design,” *IEEE Trans. Wireless Commun.*, vol. 23, no. 12, pp. 18888-18902, Dec. 2024.
- [33] Y. Cohen et al., “SINR-aware deep reinforcement learning for distributed dynamic channel allocation in cognitive interference networks,” *IEEE Trans. Wireless Commun.*, vol. 24, no. 1, pp. 228-243, Jan. 2025.
- [34] Y. Zhang and D. Guo, “Multi-agent reinforcement learning for multi-cell spectrum and power allocation,” *IEEE Trans. Commun.*, vol. 73, no. 8, pp. 5980-5992, Aug. 2025.
- [35] K.-H. Lee, H.-W. Lee, H. Lee, S. H. Chae, Y. Kim, and B. C. Jung, “minFAST: Minimum span frequency assignment technique for integrated access and backhaul networks,” *IEEE Trans. Veh. Technol.*, vol. 72, no. 6, pp. 8222-8227, Jun. 2023.
- [36] K.-H. Lee, H.-W. Lee, and B. C. Jung, “Minimum span frequency allocation problem: A vector bin packing approach,” *AIMS Math.*, vol. 10, no. 6, pp. 13278-13295, Jun. 2025.
- [37] K.-H. Lee, S. Lee, J. Park, H. Lee, and B. C. Jung, “MUSCAT: Distributed multi-agent Q-learning-based minimum span channel allocation technique for UAV-enabled wireless networks,” *Comput. Netw.*, vol. 247, art. no. 110462, Jun. 2024.
- [38] S. Lee, S. Lim, S. H. Chae, B. C. Jung, C. Y. Park, and H. Lee, “Optimal frequency reuse and power control in multi-UAV wireless networks: Hierarchical multi-agent reinforcement learning perspective,” *IEEE Access*, vol. 10, pp. 39555-39565, Apr. 2022.
- [39] Y. Wang et al., “A comprehensive survey of multi-agent deep reinforcement learning for wireless spectrum management,” *Neurocomputing*, vol. 653, art. no. 131236, Nov. 2025.
- [40] H. Mohammadi et al., “SliceFed: Federated constrained multi-

- agent DRL for dynamic spectrum slicing in 6G,” in *Proc. IEEE Int. Symp. Dyn. Spectr. Access Netw. (DySPAN)*, May 2026.
- [41] H. B. McMahan et al., “Communication-efficient learning of deep networks from decentralized data,” in *Proc. AISTATS*, pp. 1273-1282, 2017.
- [42] H. Wang and J. Xu, “Online vertical federated learning for cooperative spectrum sensing,” *IEEE Trans. Cogn. Commun. Netw.*, vol. 11, no. 4, pp. 2317-2326, Aug. 2025.
- [43] Y. Shen et al., “Graph neural networks for wireless communications: From theory to practice,” *IEEE Trans. Wireless Commun.*, vol. 22, no. 5, pp. 3554-3569, May 2023.
- [44] X. Liu and C. Fischione, “Coordinated beamforming for multi-cell ISAC using graph neural networks,” *IEEE Trans. Wireless Commun.*, vol. 25, pp. 5876-5889, 2026.
- [45] N. Yang et al., “Decision-making large language model for wireless communication: A comprehensive survey on key techniques,” *IEEE Commun. Surveys Tuts.*, vol. 28, pp. 3055-3088, 2026.
- [46] J. Wang et al., “Radio environment knowledge pool for 6G digital twin channel,” *IEEE Commun. Mag.*, vol. 63, no. 5, pp. 158-164, May 2025.
- [47] X. Luo et al., “ISAC—A survey on its layered architecture, technologies, standardizations, prototypes, and testbeds,” *IEEE Commun. Surveys Tuts.*, vol. 28, pp. 485-526, 2026.
- [48] J. Zhang et al., “Intelligent integrated sensing and communication: A survey,” *Sci. China Inf. Sci.*, vol. 68, no. 3, art. no. 131301, 2025.

≡ 필자소개 ≡

윤 장 혁



2019년 2월: 충남대학교 전자공학과 (공학사)
2021년 2월: 충남대학교 전자공학과 (공학석사)
2021년 3월~2025년 1월: 덕산넵코스 위성항제
밍그룹 연구원
2025년 3월~현재: 아주대학교 AI융합네트워크학
과 박사과정

[주 관심분야] 무선통신, 빔포밍, 무선통신 자원 관리,
무선통신 기반 측위, 딥러닝, 강화학습, 스펙트럼 공유

정 방 철



2002년 2월: 아주대학교 전자공학부 (공학사)
2004년 8월: KAIST 전기전자공학과 (공학석사)
2008년 2월: KAIST 전기전자공학과 (공학박사)
2008년 1월~2009년 8월: KAIST IT융합연구소
연구원
2009년 9월~2010년 2월: KAIST IT융합연구소
연구교수

2010년 3월~2014년 2월: 경상국립대학교 정보통신공학과 조교수
2014년 3월~2015년 8월: 경상국립대학교 정보통신공학과 부교수
2015년 9월~2019년 8월: 충남대학교 전자공학과 부교수
2019년 9월~2025년 2월: 충남대학교 전자공학과 정교수
2025년 3월~현재: 아주대학교 전자공학과 정교수

[주 관심분야] 무선통신, 통계적 신호 처리, 정보이론, 압축센싱, 이동통신,
기계학습 기반 신호처리, 스펙트럼 공유