

面向 6G 的内生智能频谱管控关键技术研究

王先梅, 任语铮, 姜天宇, 张海君, 马旭
(北京科技大学河北省空天地智能通信重点实验室, 北京 100083)

摘要: 随着通信网络的不断演进, 用频设备将持续增长, 导致频谱资源严重稀缺。6G 内生智能通过机器学习等技术实现频谱管控, 能有效提升频谱利用率。基于此, 综述了面向 6G 的内生智能频谱管控关键技术。首先, 分析了 6G 的频谱演进趋势。其次, 构建了一种三层频谱管控分析框架, 并基于该框架对比分析了 6G 内生智能方法在协作频谱感知与动态频谱接入中的决策应用, 总结了基于区块链及机器学习的频谱管控安全保障方案。最后, 讨论了潜在挑战与未来展望。

关键词: 频谱管控; 协作频谱感知; 动态频谱接入; 机器学习; 区块链

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2026041

Survey on key technologies for native-intelligence-driven spectrum management towards 6G

Wang Xianmei, Ren Yuzheng, Jiang Tianyu, Zhang Haijun, Ma Xu

Hebei Key Laboratory of Space-Air-Ground Intelligent Communication, University of Science and Technology Beijing, Beijing 100083, China

Abstract: The evolution of communication networks is intensifying spectrum scarcity due to the growing number of frequency-dependent devices. Native-intelligence in 6G, which leverages machine learning for spectrum management, offers an effective way to enhance spectrum utilization. The research on key technologies for native-intelligence-driven spectrum management in 6G was surveyed. Firstly, emerging trends in spectrum evolution were analyzed. Secondly, a three-layer spectrum management analysis framework was established. Within this framework, native-intelligence-driven decision-making applications in cooperative spectrum sensing and dynamic spectrum access were compared, and security solutions based on blockchain and machine learning were summarized. Finally, potential challenges and future research directions were discussed.

Keywords: spectrum management, cooperative spectrum sensing, dynamic spectrum access, machine learning, blockchain

0 引言

随着 6G、物联网等新型通信系统的加速演进, 未来用频设备数量将迎来爆炸式增长, 因此对频谱资源的需求也将达到空前的高度。国际电信联盟无

线电通信部门 (ITU-R) 发布的《国际移动通信 2020 年至 2030 年流量估算》指出, 从 2020 年到 2030 年, 移动流量每年将以 55% 左右的速度增长; 从 2025 年到 2030 年, 全球移动流量将从 607 艾字

收稿日期: 2025-11-29; 修回日期: 2026-02-02

通信作者: 张海君, zhanghaijun@ustb.edu.cn

基金项目: 国家自然科学基金资助项目 (No.62225103, No.U22B2003, No.U2441227); 北京市自然科学基金资助项目 (No.L253003, No.L241008)

Foundation Items: The National Natural Science Foundation of China (No.62225103, No.U22B2003, No.U2441227), Beijing Natural Science Foundation (No.L253003, No.L241008)

节/月增长到 5 016 艾字节/月^[1]。不断增长的频谱资源需求与有限频谱资源之间的矛盾日益突出, 传统的频谱管控方式已难以为继。因此, 构建高效、智能的频谱管控策略成为当务之急。

频谱资源的稀缺性问题与其固有特性有关。电磁频谱指电磁波按频率或波长顺序排列所形成的完整谱系, 其频率范围可从几赫兹延伸至数百太赫兹, 是承载信息的基本载体。在特定时间、特定空间、特定技术条件下, 可用的特定频段是一种不可再生的资源^[2]。“不可再生”并非指物理意义上的耗竭, 而是指一旦某个频段被特定业务占用, 在同一时间和区域就无法再被其他业务使用, 单次可利用的频谱资源量总是恒定有限的。这种不可再生性使得对频谱的科学规划和高效管控至关重要。传统的频谱管控方法采取固定的静态划分方式, 将频谱划分成不同的频段并固定划拨给特定服务。尽管这种划分方式在短期内提供了相对简便的管理手段, 能够有效避免信号干扰并保障各类通信服务的稳定性, 但仍面临频谱利用率低、智能化不足等缺陷。首先, 静态频谱管控方法导致大量频段在非使用时段处于空闲状态, 而其他使用率较高的频段却造成拥挤, 大量频谱资源被浪费。其次, 这种方法高度依赖专业频谱管控机构进行人工划分, 所取得的效率难以与高昂的人力成本相匹配。

相比静态频谱管控, 动态频谱管控被视为缓解频谱稀缺问题的有效手段, 其实现过程依赖 4 个关键机制: 频谱感知、频谱分配、频谱接入和频谱切换。未来 6G 网络将与机器学习、区块链等新兴技术深度融合, 从而具备内生的智能决策能力, 这将驱动动态频谱管控向更加智能化的方向演进。目前, 智能频谱管控已得到了广泛的研究。Arjoun等^[3]对频谱感知技术进行了分类, 详细回顾了传统的频谱感知技术与基于机器学习的频谱感知技术。Syed 等^[4]详细介绍了用于频谱感知的几种深度学习方法。Wang 等^[5]总结了认知无线网络 (cognitive radio network, CRN) 中基于强化学习 (reinforcement learning, RL) 方法的频谱分配策略。这些文献仅关注频谱管控中的单个机制, 缺乏全面的总结。Puspita 等^[6]讨论了 CRN 中的频谱管控问题, 但仅关注 RL 方法, 监督和无监督学习等其他机器学习方法并没有得到讨论。Kaur 等^[7]对应用于频谱

管控各机制的机器学习方法进行了全面的调查, 但忽略了频谱管控中存在的安全性问题。

因此, 针对现有工作的局限性, 本文从以下几个方面对面向 6G 的内生智能频谱管控关键技术进行深入研究。

1) 总结了目前 5G 频段的划分情况以及未来 6G 频谱资源划分的演进趋势, 指出了演进过程中高频通信与设备激增产生的对频谱管控的紧迫需求。针对这一背景, 提出了一种面向 6G 的内生智能三层频谱管控框架, 涵盖频谱感知层、动态接入层与安全保障层, 阐述了各层的功能与关系, 并进一步介绍了该框架可映射的集中式与分布式网络拓扑结构。

2) 围绕所提出的频谱管控框架展开, 介绍了传统频谱感知技术及其基于智能反射表面 (reconfigurable intelligent surface, RIS) 的改进技术, 并对比分析了基于监督学习、无监督学习和 RL 的协作频谱感知 (cooperative spectrum sensing, CSS) 方法。此外, 引入了动态频谱接入 (dynamic spectrum access, DSA) 中的动态专用、开放共享与分层接入模型, 重点论述了基于深度强化学习 (deep reinforcement learning, DRL) 的 DSA 方法。最后, 归纳了频谱管控中的安全与隐私威胁, 并探讨了区块链和机器学习技术在构建可信频谱管控系统中的应用。

3) 指出了 6G 内生智能频谱管控面临的时效、节能、干扰管理、内生安全和标准化方面的潜在挑战, 并给出了对未来的展望。

1 频谱演进趋势分析

本节分析了频谱资源划分的未来演进趋势, 指出了未来频谱面临的难拓展、高拥挤两类关键性挑战, 为构建高效频谱管控策略提供基础支撑。目前, 5G 已在全球范围内大规模商用, 下一代 6G 技术预计在 2030 年左右实现商用。第三代合作伙伴计划 (3rd generation partnership project, 3GPP) 的 Release 17 规范将 5G 新空口的频率范围 (frequency range, FR) 划分为 FR1 (即 Sub-6 GHz 频段) 和 FR2 (即毫米波频段), 并将 FR2 进一步划分为 FR2-1 和 FR2-2。其中, FR1 频率范围为 410~7 125 MHz, FR2-1 频率范围为 24.25~52.6 GHz, FR2-2 频率范围为 52.6~71 GHz^[8]。基于国际标准,

各个国家和地区结合自身情况对5G频谱进行了具体划分,中国、美国、欧盟的5G频段划分情况如表1所示。

表1 中国、美国、欧盟的5G频段划分情况

国家或地区	低频段 (<1 GHz)	中频段 (1~6 GHz)	高频段 (>6 GHz)
中国	700 MHz	2.6 GHz 3.3~3.6 GHz 4.8~5 GHz	24.25~27.5 GHz 37~43.5 GHz
美国	600 MHz 700 MHz	2.5 GHz 3.5 GHz 3.7~3.98 GHz	27.5~28.35 GHz 37~38.6 GHz 38.6~40 GHz 64~71 GHz
欧盟	700 MHz	3.4~3.8 GHz	24.25~27.5 GHz 31.8~33.4 GHz 40.5~43.5 GHz

未来6G将融合多个频段,涵盖现有的Sub-6 GHz频段和毫米波频段,并以具有高容量和良好覆盖范围的厘米波频段和具有极高数据速率的亚太赫兹频段为基础。2023年,我国工业和信息化部发布新版《中华人民共和国无线电频率划分规定》,率先将6 425~7 125 MHz全部或部分频段用于5G/6G系统^[9]。ITU-R在2023年世界无线电通信大会上完成了新一轮对《无线电规则》的修订,确定以4 400~4 800 MHz、7 125~8 400 MHz和14.8~15.35 GHz三大频率范围作为6G系统的潜在候选研究频段。此外,在我国的主要推动下,全球大部分国家和地区新划分了6 425~7 125 MHz共700 MHz带宽的中频段6G频谱资源。大会还首次将92~300 GHz的亚太赫兹频段纳入研究范围^[10]。5G和未来6G的频谱使用情况如图1所示。

尽管6G将向亚太赫兹甚至太赫兹频段扩展,但未来对频谱的使用仍面临高频通信缺陷与用频设备激增两大挑战。

1) 高频通信存在诸多缺陷。亚太赫兹和太赫兹等高频段的路径损耗极其严重,尤其是空气分子对高频信号的吸收作用,会导致传输距离大幅缩短^[11]。此外,高频段的波长较短,使基站的覆盖范围明显降低,这不仅要求更密集的基站部署,还会导致建设成本的激增。当前中低频段的优质频谱资源也已经消耗殆尽,难以满足未来通信系统对频谱的大量需求。

2) 未来用频设备激增。6G的愿景不再局限于地面移动宽带,而是迈向覆盖空天地海的智能互联网络。ITU-R于2023年发布的《国际移动通信面向2030及未来发展的框架和总体目标建议书》在5G三大应用场景(增强型移动宽带、超高可靠低时延通信和海量机器类通信)的基础上定义了6G的六大应用场景^[12](沉浸式通信、超大规模连接、超高可靠低时延通信、泛在连接、通信人工智能一体化、通信感知一体化)。六大场景极大拓展了通信的维度与边界,但随之而来的是用频设备类型与数量的爆炸式增长:智能设备、不同轨道的卫星、自主飞行的无人机、遍布各地的传感器等,都将作为新的节点接入网络。大量的设备同时竞争频谱资源,导致频谱资源的拥挤现象愈发严重。

面对上述挑战,频谱管控的重要性日益凸显。频谱管控的基本思想是允许不同的用户、设备或业务在相同的频段上同时使用频谱资源,而不是传统的排他性的分配方式。通过频谱管控,可以更高效地利用有限的频谱资源,提高频谱的利用率。在6G时代,人工智能(artificial intelligence, AI)与通信技术的融合将实现从5G的补丁式、外挂式到6G的原生式、内置式的跃迁。2025年,中国联通研究院发布的《中国联通6G网络内生智能白皮书》^[13]指出,6G内生智能网络通过在系统内引入端到端的AI能力,实现自感知、自




图1 5G和未来6G的频谱使用情况

分析、自决策、自执行的高度自治网络。利用 6G 内生智能实现频谱管控，将成为缓解频谱资源紧张问题的关键手段之一，能够为通信技术的持续发展提供有力的支持。本文探讨的面向 6G 的内生智能频谱管控的核心在于将智能能力深度内嵌于 6G 网络频谱管控架构中，实现频谱资源从感知到决策再到接入的安全闭环自治，这有别于在现有网络上进行功能增强的外挂式应用。本文重点讨论的机器学习、区块链等技术，是实现此种内生能力、构建自优化频谱管控体系的关键使能技术。

2 频谱管控分析框架

当前对频谱管控的分析主要遵循认知无线电循环结构框架，但该框架并未将安全性纳入考量范围。本节提出了一种面向 6G 的内生智能频谱管控三层分析框架，旨在实现频谱的协作感知、动态接入与可信共享。认知无线电由 Mitola^[14]首次提出，这为频谱管控提供了一种解决方案。认知无线电将用户划分为两类：一类是拥有频谱使用许可的主用户（primary user, PU），另一类是没有频谱使用许可但寻求接入机会的次用户（secondary user, SU）。CRN 的核心原理是通过频谱感知、频谱分析、频谱决策等机制，使 SU 能够在不干扰 PU 的情况下，实时监测 PU 暂时未使用的“频谱空穴”，动态地调节自身的频率使用。当外部电磁环境发生变化，PU 重新启用某频段时，SU 需迅速迁移到其他空闲信道以避免干扰，从而最大化频谱资源的利用率。这种“感知-配置”的不断循环过程，构成了认知无线电循环结构框架^[15]。基于认知无线电的思想，结合 6G 以业务为中心的发展趋势，本文从业务的角度将用户划分为关键业务用户（mission-critical user, MCU）和弹性业务用户（elastic service user, ESU），并进一步考虑了频谱管控的安全保障问题，提出了一种改进的三层频谱管控分析框架，如图 2 所示，该框架包括频谱感知层、动态接入层和安全保障层。其中，频谱感知层和动态接入层负责实现频谱管控的基本过程，安全保障层则负责防止恶意用户对频谱感知、动态接入等过程进行攻击。此外，在框架的各层级中引入 6G 内生智能，可实现频谱管控的智能化转变。

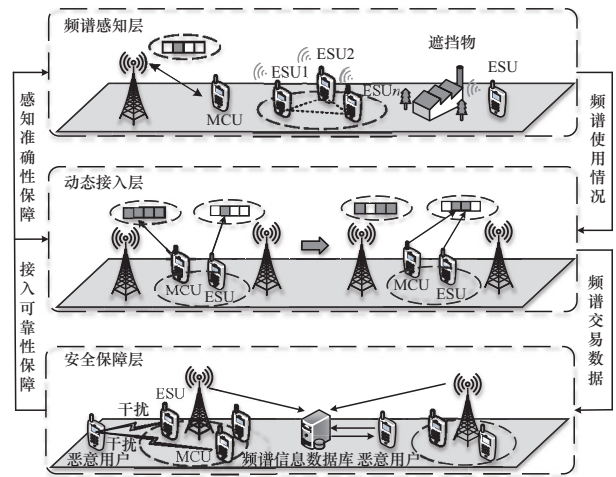


图 2 频谱管控分析框架

1) 频谱感知层。频谱感知的主要作用是从外部电磁环境中提取信号特征来确定 MCU 对频谱的占用情况，即哪些信道正在使用，哪些信道空闲。在频谱感知过程中，单个 ESU 可能会受到地理位置或障碍物等因素的影响，错误地将信道判断为空闲并开始传输，从而对 MCU 造成严重的干扰。这种问题被称为隐藏节点问题^[16]。为克服该问题的局限性，该层可采用 CSS 的策略。CSS 通过增加 ESU 的数量，使多个 ESU 间共享本地感知信息，并进行协同决策，从而显著提高检测概率。

2) 动态接入层。在实际研究中，DSA 指的是从频谱分配、频谱接入到频谱切换的全过程。频谱分配从频谱感知层中获取频谱使用情况，并将用户分配到可用的信道上。此外，频谱分配还可以接收来自频谱切换机制的频谱请求，检查并向用户分配新的信道。频谱接入则根据频谱分配的结果，为分配的用户在特定信道上建立通信链路，以保证数据传输。所谓动态，是指用户对频谱的使用不是固定的，其实现依赖于频谱切换机制。频谱切换是指若当前使用的信道因 MCU 重新占用、干扰等因素无法继续使用时，为保障通信服务不中断，ESU 主动迁移到另一个可用信道的过程。

3) 安全保障层。在频谱管控的过程中，无法保证所有的参与用户都是可信的。恶意用户可能在任何时间对频谱感知、动态接入等关键过程进行渗透与攻击，不仅造成频谱使用混乱，也会严重威胁参与频谱管控用户的隐私。安全保障层并不直接参与频谱的感知与接入等过程，而是作为一种贯穿始终的监督与保障机制。具体而言，安全保障层致力

于为频谱感知层提供一个可信的数据融合环境,防止感知决策被恶意信息误导;同时,它确保了动态频谱接入层信道分配与切换的公平与有序,避免通信服务被恶意劫持或中断。

上述三层频谱管控分析框架从功能逻辑的视角,抽象并涵盖了实现高效、可靠频谱管控所需的核心环节,可映射到不同网络拓扑结构中。按网络的拓扑结构划分,频谱管控可分为集中式管控和分布式管控。集中式管控通过一个中心控制节点来统一监控和分配资源,中心控制节点的计算复杂度将随着频谱请求的数量而增加,且容易造成单点故障。分布式管控则不需要中心控制,所有网络用户都参与频谱管控的过程,通过本地感知、协商或竞争机制自主协调频谱使用,对于高频谱需求,这是一种更常用的解决方案^[17]。

3 协作频谱感知技术

频谱感知是进行频谱管控的前提。本节首先介绍了3类传统的频谱感知方法和基于RIS的增强频谱感知方法,重点对比分析了基于机器学习的CSS技术,依次介绍了监督学习、无监督学习以及包括多智能体强化学习(multi-agent reinforcement learning, MARL)在内的RL方法在频谱感知领域的研究进展。

3.1 传统频谱感知技术及其改进

频谱感知的主要目的是监测空闲频谱资源。在ESU进行数据传输前,需要收集并分析MCU的信号以确定MCU的存在性,防止对MCU产生干扰。这一过程可以建模为一个二分类假设检验问题^[18]。传统的频谱感知技术包括能量检测、匹配滤波器检测和循环平稳检测^[19]等,这3种方法涵盖了从无先验知识到完整先验知识、从时域到循环平稳域的不同检测理念,是基于机器学习的频谱感知方法的传统基准。能量检测不需要任何先验的MCU信号知识,其主要原理是通过计算接收信号在特定频带和时间内的能量,并与一个预设的门限值进行比较,来判断MCU信号是否存在;匹配滤波器检测则需要已知MCU信号的先验信息,使接收信号通过一个与其“匹配”的滤波器,这样可以在输出端最大化信噪比,进而采样并与门限值进行比较,做出最可靠的判决;循环平稳检测是一种利用信号内在周期性的检测方

法,许多人工调制信号具有内在的周期性,这种周期性会导致信号的统计特性(如均值、自相关函数)随时间呈周期性变化,这种信号被称为循环平稳信号,而噪声通常是一个平稳随机过程,不具备这种周期性,通过检测这种周期性可以区分信号和噪声。针对传统能量检测技术难以在6G毫米波和太赫兹系统极短的感知窗口内实现高精度检测的缺陷,Zang等^[20]提出了基于概率加权的自适应能量检测频谱感知方法。该方法在链路建立阶段采用半双工感知,在数据传输阶段采用全双工感知,并根据感知样本出现有效信号的概率分布动态分配权重。相较于传统能量检测,该方法在满足相同虚警概率的前提下,将感知时间缩短约60%,适用于6G中对感知时延要求严苛的增强型毫米波及太赫兹通信感知一体化场景。

6G将使用毫米波乃至太赫兹频段,信号面临更严重的路径损耗和遮挡效应,传统频谱感知方法的检测性能在弱信号环境下可能会急剧恶化。RIS作为6G的一项关键使能技术,其可重构的反射单元可动态调控无线信号的相位与方向,在信号传播路径中构建增强的反射链路,显著提升感知信号的强度与检测可靠性。因此,一些研究者聚焦于6G中的RIS技术对频谱感知进行增强,在有限的感知时间内有效提高了CSS的性能。6G基于RIS的频谱感知技术如图3所示。Xie等^[21]构建了基于能量检测的感知框架,系统比较了RIS在被动感知与主动感知两种模式下的频谱感知性能,并深入探讨了所需反射元件数量对感知效果的影响。Liu等^[22]针对传统能量检测对噪声不确定性敏感的问题,提出了一种基于RIS的频谱感知算法——能量比检测。该方法利用任意两个ESU接收信号能量的比值作为检测统计量,使检测阈值不需要依赖噪声功率的先验知识。通过最大化所有用户的总信噪比来优化闭合形式的RIS相移,显著提升了检测性能。Ge等^[23]针对数据融合和决策融合两种典型的协作感知机制,分别提出了相移矩阵优化问题,并将其转化为信道增益相关的优化问题,利用半定松弛和高斯随机化方法求解,成功地在有限的感知时间内显著提升了CSS的性能。此外,作者还将方法扩展到瞬时信道状态信息不可用场景,分析了达到目标检测概率所需的反射

元件数量。然而，传统频谱感知方法依赖于基于严格统计模型的预定义判决门限。近年来，机器学习凭借其从环境中学习的能力以及适应环境变化的能力，实现了优于传统频谱感知算法的检测精度。

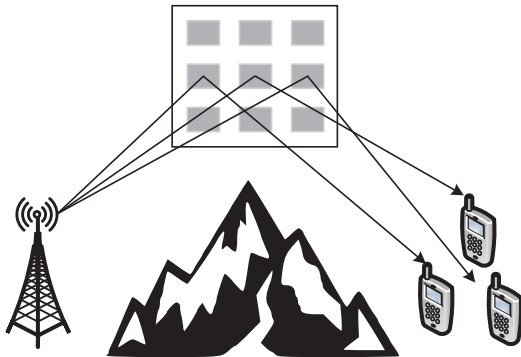


图3 6G基于RIS的频谱感知技术

3.2 基于机器学习的协作频谱感知技术

机器学习能够应用复杂的数学计算来分析和解释数据中的结构和内在规律，实现推理和决策，因此受到了越来越多的关注，并在许多领域得到了应用。将机器学习与CSS相结合，智能地检测空闲频段，是频谱感知的一个趋势。基于机器学习的CSS的基本思想是对多个ESU接收到的MCU信号进行特征提取，输入训练好的分类器，然后分类器在空

闲或占用两种状态之间做出最终决策。基于机器学习的CSS模型如图4所示。




图4 基于机器学习的CSS模型

机器学习在频谱感知中的应用主要分为三大类：监督学习、无监督学习和RL。解决频谱感知分类问题的常用机器学习方法^[24-47]如表2所示。

基于监督学习的频谱感知研究多以特征向量为切入点展开。Coluccia等^[24]提出一种基于高阶特征映射的支持向量机（support vector machine, SVM）频谱感知方法，将能量、特征值比值和协方差矩阵比值3类经典感知统计量及其高阶组合作为特征向量输入SVM分类器，该方法不需要噪声方差信息。结果显示，高阶SVM在接收者操作特征曲线上的表现优于传统检测方法，尤其在弱信号检测方面表现突出。Vyas等^[25]提出了一种混合型频谱感知方

表2 解决频谱感知分类问题的常用机器学习方法

类别	算法	核心思想
监督学习	SVM ^[24, 27-29]	在特征空间中寻找最优超平面，以最大间隔对接收信号特征进行分类
	RF ^[27, 29]	集成多个决策树，通过投票机制决定最终分类结果
	ANN ^[25]	通过多层互连的神经元对输入的特征向量进行非线性变换，输出分类概率
	NBM ^[29]	基于贝叶斯定理和特征条件独立假设，计算给定特征下信道状态的后验概率
	LR ^[27]	通过Sigmoid函数将特征的线性组合映射到(0,1)，输出MCU存在的概率
无监督学习	KNN ^[27-28]	在特征空间基于距离将未知状态信号样本归类于K个最近邻样本中最普遍类别
	K-Means ^[30-31]	在无先验标签情况下，将信号样本根据特征自动聚成K个簇，以推断信道状态
	PCA ^[33]	对高维感知数据进行线性降维，保留主要变异信息，作为后续分类的预处理步骤
RL	GMM ^[30-36]	假设感知数据由多个高斯分布混合生成，通过期望最大化算法估计参数，对数据分布进行概率建模。在感知中，可将不同高斯分量对应于“空闲”与“占用”等状态
	Q-Learning ^[40,47]	智能体通过与环境交互，根据状态和奖励，学习最优的感知策略
	DQN及其变体 ^[42]	利用深度神经网络来近似Q值函数，以处理多用户、多信道等高维状态空间
	MARL ^[45-46]	每个ESU作为独立智能体在环境中协同学习感知与决策策略，以优化整体系统性能

案,将经典能量检测、似然比检验统计量与人工神经网络(artificial neural network, ANN)相结合。该方案使用能量值和Zhang等^[26]提出的检验统计量作为ANN的输入特征,并创新性地引入了前一刻的感知特征以增强学习过程的鲁棒性,展现了ANN在融合多特征并进行非线性分类方面的优势。Saravanan等^[27]提出了一种基于差分熵的监督学习频谱感知方法,将差分熵作为特征向量,训练了SVM、K近邻(K-nearest neighbor, KNN)、随机森林(random forest, RF)和逻辑回归(logistic regression, LR)等分类器。在低信噪比和重尾噪声条件下,基于差分熵的方法优于能量检测方法,尤其在噪声分布偏离高斯假设时表现更鲁棒。Hu等^[28]引入了几何功率作为频谱感知的特征向量,并结合监督学习算法进行分类。此外,作者在真实数据集上对比了几何功率、能量统计和差分熵3种特征的性能,发现基于几何功率的感知方法在低信噪比下具有更高的检测概率。Krishnan等^[29]研究了在广义衰落信道下基于特征值的频谱感知方法,比较了最大特征值、能量和最大-最小特征比等特征,并采用SVM、朴素贝叶斯模型(naive Bayesian model, NBM)和RF等方法进行分类。结果表明,最大特征值特征在多种衰落场景下均表现最优,且线性SVM在所有分类器中性能最佳,为多节点协作感知提供了有效的解决方案。

监督学习方法在检测频谱可用性方面取得了显著成效,但其应用仍受限于一个关键问题:模型训练依赖大量已标注数据,这在实际频谱感知场景中往往难以获取。因此,越来越多的研究者将目光转向无监督学习。与监督学习不同,无监督学习不需要依赖关于信道状态或MCU活动的先验标记信息,而是直接从自然采集、未经标注的感知测量数据中提取信号特征,再通过聚类、关联分析或降维等手段,从这些数据中自主挖掘出隐藏的规律或关联性。

基于无监督学习的频谱感知研究中,最常用的两个方法是K-means聚类和高斯混合模型(Gaussian mixture model, GMM)。Thilina等^[30]系统地将机器学习方法引入CSS,讨论了无监督学习中的K-means、GMM分类器和监督学习中的SVM、加权KNN分类器,并将各ESU估计的能量水平作为特征向量,用于判断信道是否被MCU占用。

Sobabe等^[31]则引入从接收信号协方差矩阵中提取的特征值与特征向量作为感知特征,替代传统的能量向量,使用K-means聚类与GMM进行分类,该方法在低信噪比条件下显著优于Thilina等^[30]提出的基于能量特征的感知方法,在低虚警概率要求下仍保持较高的检测性能,但其计算复杂度相对较高。针对将接收信号协方差矩阵的特征值压缩为单一决策统计量后导致信息损失的问题,Majumder等^[32]提出一种基于GMM的盲频谱感知方法,将全部特征值构建为多维决策向量,通过期望最大化算法提取GMM参数,在未校准的多天线场景中实现了高精度检测。

尽管无监督学习在频谱感知中减轻了数据标记的负担,但其检测性能常因缺乏标记样本的引导而成为瓶颈,为此许多研究者对传统无监督学习方法进行了改进或与监督学习方法进行结合使用。Khalek等^[33]针对标记数据稀缺的问题,提出了一种基于GMM与主成分分析(principal component analysis, PCA)的无监督学习框架。通过PCA对高维能量向量进行降维,提升GMM的训练效率与泛化能力。该框架在不需要先验环境知识与标记数据的情况下,实现了与SVM、RF、决策树等监督学习相媲美的检测性能,在低信噪比环境下表现稳健。Khalek等^[34]还提出了一种两阶段无监督学习框架,第一阶段使用GMM对未标记能量向量进行聚类并生成伪标签,第二阶段利用这些伪标签训练SVM分类器。该框架在保持无监督优势的同时,性能接近监督学习,且显著优于单GMM。Chávez等^[35]同样使用GMM对从实际信号中提取的特征值进行聚类并生成伪标签,再利用这些伪标签训练深度神经网络(deep neural network, DNN)。该两阶段训练策略在真实信道环境下性能接近奈曼-皮尔逊最优检测器,且优于多种基于模型的Hadamard检测器。Khalek等^[36]提出了一种名为DeepSense的无监督深度学习框架,DeepSense结合稀疏自编码器进行特征表示学习和GMM进行无监督聚类,DeepSense训练只需要少量未标记的数据,就能够达到优于纯GMM且与基于深度监督学习的协作感知基准相当的检测性能。

不同于监督/无监督学习,RL不需要预先存在的数据集^[37],而是通过环境与智能体进行动态交

互, 通过试错和奖励机制学习最优决策策略, 最大化长期累积奖励^[38]。在 CSS 的 RL 框架中, “环境”一般指的是由无线信道、MCU 以及其他 ESU 共同构成的动态系统; 融合中心 (fusion center, FC) 作为智能体^[39], 负责汇总来自多个 ESU 的本地感知数据, 并执行关于 MCU 存在与否的最终决策。例如, Lo 等^[40]关注一个授权信道上的一个 ESU 及其一跳邻居的 CSS, 将发起 CSS 的 ESU 作为 FC (即智能体), 该 ESU 向其所有一跳邻居广播协作感知的请求, 选定的合作邻居通过执行本地感知并返回其本地决策来响应此请求, 最终 FC 使用计数和多数规则来确定关于 MCU 的存在性的决策, 并将该决策广播给所有邻居。

在集中式 CSS 中, 将感知结果转发到 FC 会产生传输开销。Lo 等^[40]针对 CSS 带来的控制开销、感知时延、能量效率低以及因阴影效应导致的检测性能下降等问题, 提出了一种基于 RL 的新型 CSS 模型, 该模型通过选择最佳的协作邻居集, 以最大限度地降低总协作感知时延和最大化能量效率, 成功提高了阴影效应下的检测性能。Jalil 等^[41]提出了一种两阶段离线 DRL 的 CSS 方法: 首先, 每个 ESU 利用离散保守 Q 学习 (discrete conservative Q-learning, DCQL) 模型基于本地感知结果预测当前及未来时隙的 MCU 状态; 其次, FC 整合所有用户的预测结果, 再使用 DCQL 模型生成全局决策。该方法使 ESU 不需要在每个时隙都进行感知, 在降低了能耗和传输开销的同时提高了频谱利用率和延长了传输时间, 适用于多种 MCU 活动模式。Xu 等^[42]提出了一种基于 DRL 的 RIS 辅助 CSS 框架, 并设计了一种改进的竞争双 Q 网络 (dueling double deep Q-Network, D3QN) 算法, 用于动态选择最优的参与感知用户子集以及优化 RIS 的相移配置, 在提升感知性能的同时减少了约 50% 参与感知的用户数量, 有效节省了系统资源与能耗。Chen 等^[43]将联邦学习 (federated learning, FL) 引入 CSS, 提出了一种基于 FL 的频谱感知 (federated learning-based spectrum sensing, FLSS) 算法。FLSS 使用轻量级神经网络 ShuffleNetV2 在各用户本地训练模型, 仅将模型梯度上传至 FC 进行聚合, 显著降低了通信开销。Yang 等^[44]进一步将 RIS 与 FL 结合, 提出了一种名为联邦频谱学习的框架, 以应对无线边缘网络中

因深度衰落信道导致的频谱感知不可靠问题。该框架在每个 RIS 控制器部署预训练的卷积神经网络模型, 用于帮助基站协同推断参与 FL 的用户请求。当 RIS 数量和反射元件增多时, 能够显著提高频谱预测精度和系统效率。

此外, 集中式 CSS 通常只有一个 FC, 当该 FC 损坏时, 集中式协作感知将无法进行, 因此系统的可靠性较差。与集中式 CSS 相比, 分布式 CSS 不依赖 FC 进行统一决策, 决策权下放给了各个 ESU, 它们通过在通信范围内反复交互, 最终收敛到一个统一的决策。这种方式能够避免单点故障和高时延等问题。MARL 将每个 ESU 建模为独立的智能体, 符合分布式 CSS 的特性。Zhang 等^[45]采用 MARL 方法, 并采用 Hoeffding 型置信上界策略来提升探索效率, 实现了比 ϵ -贪婪策略的传统 RL 方法更快的收敛速度与更优的奖励性能。Lundén 等^[46]提出了一种分布式多智能体、多频带的 CSS 策略, 每个 ESU 通过与邻居进行本地信息交互来协作学习频谱感知策略, 旨在最大化发现的可用频谱量, 通过控制同时感知同一频段的用户数量来保证感知可靠性。Das 等^[47]提出了一种基于协作 Q 学习的频谱感知方法, 通过结合 ESU 本地历史感知经验与邻居节点共享信道状态信息, 动态生成信道的优先级列表, 以指导 ESU 按优先级顺序扫描信道, 在降低扫描开销和计算复杂度的同时, 显著提升系统响应速度并减少阻塞与掉线率。

4 动态频谱接入技术

DSA 是实现频谱管控的核心手段。本节首先介绍了动态专用、开放共享与分层接入 3 种 DSA 模型, 然后重点探讨了基于 DRL 的动态接入技术, 全面梳理了其解决部分可观测、精准建模与干扰规避等关键问题的研究进展。

4.1 动态频谱接入模型

DSA 是实现 6G 动态频谱管控的关键技术之一, 其核心思想是动态地、机会性地接入当前空闲的频谱资源。按照频谱授权方式, DSA 可划分为 3 种模型, 即动态专用模型、开放共享模型和分层接入模型^[48]。

1) 动态专用模型是对传统静态分配的改进, 该模型仍将频谱资源通过许可方式授予服务提供商独家使用, 但它不再将频谱永久性地分配, 而是通

过一种短期、灵活的授权机制来分配频谱的使用权,从而提升频谱使用效率。在此框架下,主要有两种解决方案:频谱产权制度^[49]与动态频谱分配机制。频谱产权制度允许频段持有者自由租赁、出售或共享频谱以获取利润,但是这种行为缺乏监管政策的限制。Weiss等^[50]提出了一种频谱产权错配框架,在时间、频率、功率及信号质量等多维度上重新划分频谱使用权,并构建了一种适应性监管机制,成功平衡了不同用户间的频谱使用权益。动态频谱分配机制由欧洲“车载环境动态无线电IP服务计划”提出^[48],其核心思路是将频谱资源临时分配给特定的用户或业务,满足其通信需求,并随着时间、地点、用户需求等因素的变化动态调整。

2) 在开放共享模型中,频谱不再由频谱管控机构授权给特定的用户独占使用,而是被视为共享资源,用户以平等的身份接入这些频谱资源。这种模型已得到应用,最典型的例子是多个相邻的Wi-Fi网络在2.4 GHz或5 GHz非授权频段上运行,它们遵循相同的载波监听多路访问/冲突避免协议,通过“先监听后发言”的分布式机制来协商信道访问权,避免冲突。

3) 分层接入模型的核心思路是限制MCU受到干扰的同时允许ESU接入未被MCU使用的频谱。该模型将接入方式分为3种:覆盖(Overlay)、衬底(Underlay)和交织(Interweave)^[51],3种接入方式的原理如图5所示。Overlay方式的核心思想是ESU通过中继或错误纠正等方式主动协助MCU来换取频谱使用权,从而抵消或补偿其接入对MCU造成的干扰。这种方式不要求ESU严格限制自身发射功率,而是通过合作通信的方式提高整体频谱效率,其实现复杂度通常较高。Underlay方式允许MCU与ESU在同一时间、同一频段内同时传输,但ESU的发射功率受到严格限制,以确保不会对MCU造成过大的干扰。Interweave方式也称为机会频谱接入,其核心思想是“避让”,ESU会持续地感知周围的无线环境,主动寻找并检测未被MCU使用的“频谱空穴”。一旦发现这样的空闲频段,ESU就迅速接入并进行通信;当监测到MCU重新使用某频段时,ESU必须立即退出该频段以免产生有害干扰。

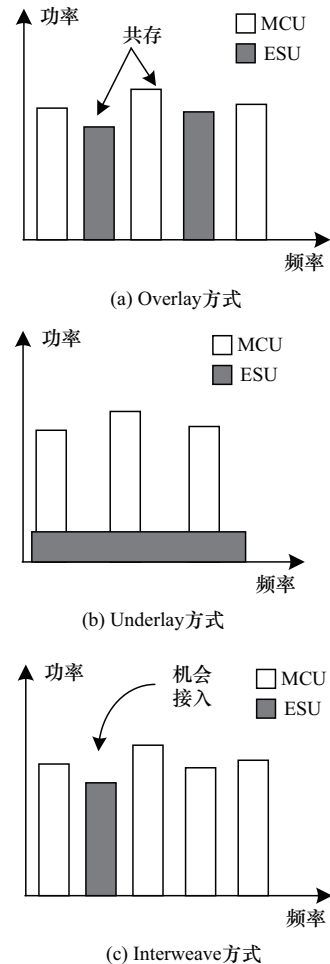


图5 分层接入模型的3种接入方式

4.2 基于深度强化学习的动态频谱接入技术

传统的DSA方法依赖先验的网络动态知识来建立网络模型。Zhao等^[52]提出的Myopic策略总是选择眼前回报最大化的渠道,这种策略只有当状态转移是正相关或略负相关时,性能才能达到最优。Liu等^[53]提出的Whittle Index策略只有在所有信道独立但不完全相同时,性能才能达到最优。这两种策略都假设信道独立且状态转移矩阵已知,难以在实际的网络中应用。在实际的网络中,用户通常无法在线获取完整的网络状态信息。此外,网络动态特性会随信道用户的不断变化而持续演变,这种高度不确定性与复杂性使得难以构建一个能够精确描述环境动态的数学模型。Li等^[54]将Q学习的方法应用于CRN的频谱接入,但传统Q学习方法仅能应对小规模模型,面对实际网络中存在的大规模状态空间和部分可观测性问题时,Q学习方法的效率会显著降低。

针对上述问题，许多研究者将DRL的方法应用于DSA中。DRL融合了DNN的多维感知能力和RL的自主决策能力，其基本结构如图6所示。最重要的是，DRL可以无模型的，即不需要网络的先验知识对环境进行预先建模，而是智能体通过与周围环境的反复交互来学习。




图6 DRL结构

表3归纳了不同动态频谱接入场景下的DRL方法。

在单用户接入方面，Wang等^[55]研究了单用户

动态接入多信道的问题，针对信道相关与系统动态未知的场景，将问题建模为部分可观测马尔可夫决策过程（partially observable Markov decision process, POMDP），提出基于DRL的深度Q网络（deep Q-network, DQN）方法，实现了优于传统Myopic和Whittle Index策略的性能，且能够应对时变环境。Li等^[56]分别使用DQN算法及其改进算法深度双Q网络（double deep Q-network, DDQN）解决单用户多信道接入问题，发现DDQN能有效解决DQN在特定条件下的动作价值高估问题，且收敛速度更快。Wang等^[57]针对多MCU、单ESU的交织式网络，提出了一种基于使用感知的DRL方案，该方案利用历史信道使用数据来学习MCU信道的时间相关性和信道相关性，在提高信道接入成功率和降低ESU-MCU之间的干扰概率方面实现了优于传统Q学习和DQN的性能。

在多用户接入方面，Naparstek等^[58]聚焦开放共享模型，提出了一种名为DQSA的深度多用户强化学习分布式接入算法，适用于多用户、多信道的无线网络环境。该算法在中央单元离线训练DQN，引入长短期记忆网络（long short-term memory, LSTM）处理部分可观测状态，并整合了Dueling DQN与DDQN来提升性能，在复杂多用户场景下的吞吐量可达时隙ALOHA协议的两倍。进一步，Tan等^[59]提出了一种名为QMIX-DSA的算法，将多用户、多信道的DSA问题建模为去中心化

表3 不同动态频谱接入场景下的DRL方法

应用场景	算法	核心机制	主要贡献
单用户接入	DQN ^[55]	将动态接入问题建模为POMDP，利用DQN进行决策	在信道状态相关且系统动态未知时，实现优于传统Myopic或Whittle Index策略的性能
	DDQN ^[56]	采用双网络结构解耦动作选择与价值评估	解决DQN在特定条件下对动作价值的高估问题，加快收敛速度
	DDQN ^[57]	利用历史信道使用数据学习信道的时间与空间相关性	在交织式网络中，提高接入成功率并降低对MCU的干扰概率
多用户接入	DQSA ^[58]	整合LSTM、Dueling DQN与DDQN	处理多用户部分可观测场景，在复杂环境下实现高吞吐量
	QMIX-DSA ^[59]	采用“集中训练，分布执行”框架，并利用DRQN处理部分可观测性	解决去中心化的多用户、多信道DSA问题，在动态环境中具有更好的收敛性与性能
	Fed-MADRL ^[60]	结合FL与MARL，用户仅上传量化后的策略参数	在保障协同性能的同时，大幅降低多用户间的通信开销
干扰规避	DQ3N-PER ^[61]	设计动态奖励函数，鼓励ESU避免与MCU及其他ESU发生碰撞	在保证公平性的同时，在碰撞避免和频谱利用率方面优于已有DRL方法
	DQN-RC ^[62]	将DQN与RC相结合，利用RC捕捉频谱状态的时间相关性	使ESU仅依赖自身感知历史即可做出分布式接入决策，有效减少各类碰撞

POMDP, 提出“集中训练, 分布执行”的框架, 并采用深度循环Q网络 (deep recurrent Q-network, DRQN) 来处理部分可观测性问题, 在用户数量较多或环境动态变化的场景下实现了优于DQSA的收敛速度和性能。Song等^[60]提出了一种名为Fed-MADRL的协同DSA方法, 该方法结合FL和多智能体深度强化学习, 使各用户在本地利用基于回声状态网络的策略网络进行训练, 并仅上传量化后的策略参数至FC, 避免原始数据的共享。该方法在通信开销大幅降低的情况下, 仍能达到与同步FL相当的吞吐量, 适用于B5G/6G网络中的分布式频谱管理。

除了部分可观测问题与精准建模问题, DSA中还需要考虑两类干扰问题: 一是避免ESU与MCU发生碰撞; 二是避免ESU之间发生碰撞。Jalil等^[61]针对多MCU和多ESU的场景, 提出了一种名为D3QN-PER的解决方案, 该方案设计了一种动态奖励函数, 鼓励ESU避免与MCU及其他ESU发生碰撞, 并能适应不同的MCU活动模式和频谱感知误差, 在保证公平性的同时, 在碰撞避免率和频谱利用率方面优于已有DRL方法。Chang等^[62]探讨了存在频谱感知误差的分布式DSA, 提出了一种DQN与储备池计算 (reservoir computing, RC) 相结合的策略, 利用RC来捕捉频谱状态的时间相关性, 使每个ESU仅依靠自身当前及历史的频谱感知结果就能做出分布式接入决策。该策略能有效帮助ESU减少与MCU及其他ESU的碰撞, 在信道数量较大时比传统Q学习方法收敛更快。

5 频谱管控安全保障技术

本节探讨频谱管控面临的安全挑战及其解决方案。首先, 介绍了频谱管控的过程中存在的假冒攻击、频谱信息数据库推理攻击和频谱接入拒绝服务攻击。其次, 重点论述了基于区块链的安全保障技术, 从核心特性、共识机制及智能合约等方面, 阐述了该技术在构建6G可信频谱管控环境中的研究进展。

5.1 频谱管控中的安全与隐私问题

尽管6G内生智能频谱管控在解决频谱短缺问题上具有显著的优势和广阔的前景, 但它也带来了独特的安全与隐私问题。恶意用户的主要攻击手段可归纳为假冒攻击 (impersonation attack, IA)、频谱信息数据库推理攻击 (database inference attack, DIA) 和频谱接入拒绝服务攻击 (spectrum access denial-of-service attack, SADOsa), 3类攻击手段的原理如图7所示, 具体介绍如下。

1) IA是恶意用户伪造信息或冒充合法用户身份, 误导频谱管控系统的一类攻击。根据攻击对象的不同, IA可进一步划分为频谱感知数据伪造 (spectrum sensing data falsification, SSDF)、主用户模拟攻击 (primary user emulation attack, PUEA) 和认知用户模拟攻击 (cognitive user emulation attack, CUEA)。其中, SSDF指恶意用户通过向FC发送篡改或伪造的感知结果来误导FC的决策过程, 严重降低感知系统的检测准确性。PUEA指恶意用户伪造MCU的信号, 使ESU认为频谱不空闲, 从而阻碍ESU对空闲信道的使用。Rathee等^[63]首次

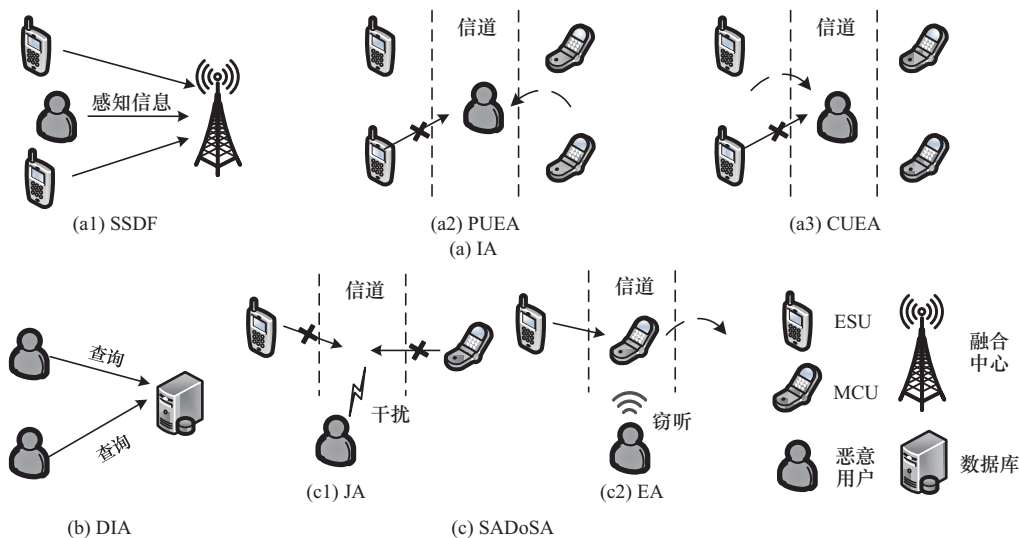


图7 恶意用户的3类攻击手段

提出了 CUEA 的概念，CUEA 指在频谱切换过程中，恶意用户利用频谱切换时延窗口冒充正在切换信道的合法 ESU，以抢占其频谱资源，导致其通信中断的攻击。

2) DIA 指恶意用户使用复杂的推理技术从数据库查询结果中推理出用户的敏感信息，威胁用户隐私。例如，在基于贝叶斯推理的位置攻击中，恶意用户可以通过多次查询数据库收集功率信息，根据功率与路径损耗估算出与 MCU 之间的距离范围，运用贝叶斯公式推断出 MCU 的精确位置，造成 MCU 位置信息的暴露^[64]。

3) SADoSA 主要包括干扰攻击 (jamming attack, JA) 和窃听攻击 (eavesdropping attack, EA) 两类。JA 中，恶意用户主动发送干扰信号影响通信链路，使合法用户无法接入或使用频谱资源，造成显性的服务中断。JA 具有动态变化的特性，使传统固定模式的抗干扰手段难以应对。EA 不直接中断通信链路，而是利用无线信道广播传播的特性，在共享频谱中非法截获传输内容，迫使通信方为避免信息泄露而主动限制或中止通信服务。Tan 等^[65]从恶意用户视角出发，针对支持 DSA 的 IEEE 802.22 网络构建了协同拒绝服务攻击模型。该研究成功演示了协同攻击的可行性，揭示了网络在缺乏安全协调机制时的固有脆弱性。

5.2 基于区块链的频谱管控安全保障技术

面对未来频谱需求不断增长与频谱资源日益复杂的安全挑战，亟须一种更加智能与安全的频谱管控技术。区块链技术凭借其去中心化、不可篡改和可追溯等特性为频谱管控中的安全与隐私问题提供了良好的解决方案，引起了业界的广泛关注。2018 年，法国国家频谱管理机构首次在 2.4 GHz、5 GHz 等频段上试验使用区块链技术^[66]；2023 年，IMT-2030 (6G) 推进组发布的研究报告《6G 可信内生安全架构》中明确指出区块链是构建 6G 内生安全的关键技术之一^[67]；Wang 等^[68]探讨了区块链技术在动态频谱管控中的应用潜力与标准化进展，回顾了包含空白电视频段、公民宽带无线电服务和授权共享接入在内的现有频谱共享标准，同时总结了区块链在通信领域的标准化进展，包括国际电信联盟 (ITU)、欧洲电信标准化协会、电气电子工程师学会 (IEEE) 和中国通信标准化协会等标准化组织的工作。

区块链是由一系列不可更改信息的“区块”按

照时间顺序构成的“链”，其本质是一个由所有参与者共同维护的分布式数据库。“区块”是区块链数据存储的基本单元，其结构由区块头和区块体两部分组成：区块头存储该区块的元数据，包括版本号、时间戳、当前区块的哈希值、前一区块的哈希值、默克尔根等字段；区块体则存储一段时间内的所有有效交易或状态数据，这些数据采用默克尔树的结构进行存储。所谓“链”，指的是每个区块的区块头中都包含前一区块的哈希值。这种设计使得对任何区块数据的篡改都会导致该区块哈希值的改变，进而破坏该区块与后续所有区块的链接关系，从而保证了数据的完整性与不可篡改性。区块链结构如图 8 所示。

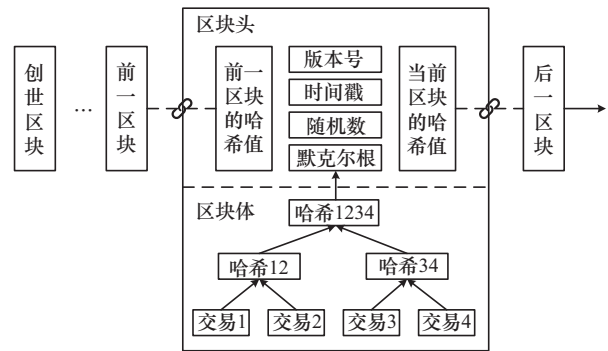


图 8 区块链结构

为构建 6G 可信频谱管控环境，许多研究者探索了区块链的共识机制、智能合约与框架设计等技术维度，相关代表性研究成果^[69-78]如表 4 所示。

利用区块链中的共识机制，可在参与频谱管控的各节点间建立一个可信的环境。在分布式、无中心节点的网络环境中，共识机制能够确保所有互不信任的节点对交易的有效性达成一致的共识^[69]。常见的共识机制包括工作量证明 (proof of work, PoW)、权益证明 (proof of stake, PoS) 和实用拜占庭容错 (practical byzantine fault tolerance, PBFT) 等。在 PoW 中，各节点基于自身算力解决一个求解复杂但容易验证的数学难题，最快解决者获得记账权；PoS 通过币龄机制赋予所有节点权益，拥有权益越多的节点获得记账权的概率越大；PBFT 则通过多轮投票在节点间达成共识。然而，传统的区块链共识机制难以直接适配频谱管控场景，研究者正积极探索新的共识算法。Liang 等^[70]提出了一种基于干扰的共识机制，根据节点在上一轮区块链

表4 基于区块链的频谱管控安全保障技术

技术维度	文献	核心机制	主要贡献
共识机制	文献[70]	基于干扰的共识机制	将物理层干扰转化为区块链共识的激励依据, 实现公平性补偿
	文献[71]	分布式感知证明	将频谱感知行为本身作为工作量证明, 节能且收集全网感知数据
	文献[72]	轻量级的PoT共识机制	降低6G大规模频谱交易的计算开销与能耗, 提升共识效率
智能合约	文献[73]	多运营商频谱共享智能合约, 设计惩罚机制约束不合作行为	实现多运营商之间安全、去中心化的动态频谱共享
	文献[74]	多运营商频谱共享智能合约, 采用双重拍卖与自由交易市场机制	适用于5G异构网络中的频谱资源交易
	文献[75]	智能合约集成信誉模型, 激励用户参与感知任务	固定预算下, 既提高了MCU的检测概率, 又提高了ESU的平均收益
框架设计	文献[76]	引入Oracle连接链上与链下, 采用PoH提高交易处理速度	以低交互成本支持6G高吞吐量的频谱交易
	文献[77]	主链+子链的分层区块链架构	实现了监管与业务、全局与本地操作的解耦
	文献[78]	结合共生通信与区块链技术, 采用分片方案处理交易	大幅降低对抗性网络中的能耗与处理时延, 有望构建可持续、可信的6G无线网络

交易中所承受的干扰程度来分配下一轮的记账权, 受到干扰最大的节点将优先获得记账权作为补偿。Fernando等^[71]针对DSA系统, 提出了一种名为“分布式感知证明”的节能共识机制, 该机制激励区块链节点进行频谱感知, 通过在无线信道中扫描并捕获由授权节点随机发射的加密密钥片段来竞争记账权。这种机制不仅避免了传统共识机制的高能耗, 还额外收集了全网频谱感知数据, 可用于后续分析和检测频谱违规行为。Liu等^[72]提出了一种面向6G、基于区块链的授权频谱公平分配方法, 针对当前5G频谱分配中因缺乏有效监管与惩罚机制而导致的不公平问题, 设计了一个去中心化的频谱分配框架, 采用轻量级的信任证明 (proof of trust, PoT) 共识机制, 以降低计算开销并提升共识效率。该方法在以太坊测试链上进行了部署与验证, 在公平性、安全性方面取得了良好表现, 为6G网络中频谱资源的智能化与自动化管理提供了可行方案。

区块链中的智能合约是保障频谱管控安全性的数字准则。在频谱管控过程中, 智能合约一般执行的是频谱管控算法, 自动完成频谱的感知、分配或交易等过程。智能合约本质上是部署在区块链上的一段预定义的程序, 当预设条件被触发时自动执行, 过程中不需要第三方介入, 可在去信任环境中实现透明、安全的自动化履约。Roopa等^[73]提出了一种基于区块链的多运营商频谱共享智能合约系统, 旨在实现多运营商之间安全、去中心化的动态频谱共享。系统部署在以太坊平台上, 支持MCU

通过智能合约交易闲置频谱, 并通过惩罚机制约束不合作行为。该方案在降低成本和保障隐私方面优于传统集中式方法。Zheng等^[74]同样聚焦多运营商频谱共享, 设计了一个基于许可区块链的多运营商频谱的共享框架, 并开发了多运营商频谱的共享智能合约。采用双重拍卖与自由交易市场机制, 支持运营商间自主交易, 并由管理员监督执行与惩罚恶意行为。该方案在隐私、公平性和开放性方面均优于传统频谱分配方法, 适用于5G异构网络环境。Zhang等^[75]针对6G网络中频谱感知的准确性与用户参与度问题, 提出一种基于智能合约的感知与激励机制。智能合约采用信誉模型激励ESU参与感知任务。该方案在相同预算下将MCU检测概率提升约19.6%, 同时提高了ESU的平均收益。

基于区块链的固有特性、共识机制与智能合约应用, Cuellar等^[76]提出了一种名为BSM-6G的动态频谱管理框架, 将区块链与认知无线电技术结合, 以提升6G动态频谱管理的互操作性与可扩展性。该框架引入了区块链预言机 (Oracle) 作为互操作模块连接区块链平台与CRN系统, 使链上智能合约能够可靠地获取并验证链下的实时频谱感知数据。在可扩展性方面, 该框架采用历史证明 (proof of history, PoH) 共识机制来提高交易处理速度。BSM-6G在保持低交互成本的同时, 能够支持高吞吐量的频谱交易, 适用于6G高动态、大规模设备连接的网络环境。Wu等^[77]提出了一种基于区块链的动态频谱共享框架SpectrumChain, 用于

6G 动态频谱共享。该框架采用分层区块链架构，包括主链和多个子链，主链负责全局性的、粗粒度的频谱交易和法规发布，子链则负责本地的、细粒度的频谱共享。SpectrumChain 实现了监管与业务、全局与本地操作的解耦，兼顾了系统的可扩展性、灵活性与可监管性，为 6G 全频谱接入提供了创新解决方案。Luo 等^[78]考虑了 6G 解决频谱问题的另一个重要潜在技术——共生通信（symbiotic communication, SC），并提出了一种将 SC 和区块链相结合的方案，称为共生区块链网络（symbiotic blockchain network, SBN）。SBN 首先利用认知反向散射通信改造传统共识机制，使无线节点间能建立共生传输关系，然后通过分片方案，将网络划分为多个并行处理交易的分片。实验结果表明，SBN 能够有效降低对抗性网络中的能量消耗和处理时延，有望实现可持续和可信的 6G 无线网络。

5.3 基于机器学习的频谱管控安全保障技术

区块链技术为频谱管控建立了静态的可信协作与交易基础。然而，面对动态变化的主动攻击，未来 6G 频谱管控系统还需具备动态智能的安全洞察能力。为进一步增强 6G 频谱管控系统的安全性能，机器学习技术已成为区块链之外另一个关键的安全增强手段。机器学习可以收集和分析网络中每个用户的行为数据，以确定正常的交互模式，从而使系统能够及早识别恶意用户攻击。此外，机器学习还可以通过探索现有记录来智能预测新的攻击^[79]。针对 PUEA、SSDF、JA、EA 及 DIA 等不同类型的攻击，研究者提出了多种基于机器学习的检测与防御方法^[80-94]，如表 5 所示。

在防御 PUEA 时，关键是如何区分恶意用户和合法 MCU。当前大部分研究采用的是基于统计分析的方法，通过位置、信号功率等多个特征联合分析发射器行为以区分用户类型。Inamdar 等^[80]提出了一种基于 KNN 和 ANN 分类器的 PUEA 检测方法。通过提取数据速率、距离、传输功率和请求频率等特征进行训练，KNN 在检测准确率上优于 ANN，达到 98%。Muñoz 等^[81]对比了 SVM、RF 和 KNN 这 3 种分类算法，结合能量与熵检测提取特征。实验表明，SVM 在低信噪比条件下表现最佳，检测概率比传统能量检测器提升约 8%，且适用于移动环境中的实时检测。Dong 等^[82]讨论了基于循环神经网络（recurrent neural network, RNN）的 PUEA 检测方

法，比较了基本 RNN、单层 LSTM 和多层 LSTM 在复杂 MCU 活动模型下的表现，发现多层 LSTM 能够更好地捕捉长时间依赖关系，在 PUEA 检测中表现最优，该方法适用于资源受限的 6G 频谱管控环境。然而，在实际 6G 网络中，攻击者的信息可能完全未知。因此，Xu 等^[83]提出了一种结合深度学习与极值理论（extreme value theory, EVT）的频谱感知方法。该方法不需要攻击者信号的先验信息，通过建立基于 EVT 和 Weibull 分布的概率模型，设计了一种名为 SDCNN 的网络提取多域特征，实现了对已知 MCU 和未知恶意用户的高效识别。

表 5 基于机器学习的频谱管控安全保障技术

文献	攻击类型	算法	算法类型
文献[80]	PUEA	KNN、ANN	监督学习
文献[81]	PUEA	SVM、RF 和 KNN	监督学习
文献[82]	PUEA	RNN、LSTM	深度学习
文献[83]	PUEA	SDCNN	深度学习
文献[84]	SSDF	模糊 C 均值聚类	无监督学习
文献[85]	SSDF	贝叶斯学习	无监督学习
文献[86]	SSDF	DQN	DRL
文献[87]	JA	Minimax-Q 学习	MARL
文献[88]	JA	Minimax-Q、Nash-Q 和 Friend-or-Foe Q 学习	MARL
文献[89]	JA	SARSA 和 QV 学习	MARL
文献[90]	JA	TGACT	RL+迁移学习
文献[92]	EA	模糊 MDP-Q 学习	RL
文献[94]	DIA	SVM	监督学习

在防御 SSDF 时，关键是如何区分恶意用户和合法 ESU。现有的防御方法分为两类，即基于异常值的方法和基于信誉度的方法。在基于异常值的方法中，一旦将某个用户判定为异常，就立即完全禁止其参与 CSS 过程，其数据不再被接收。在基于信誉度的方法中，每个参与 CSS 的 ESU 都根据其历史表现被分配一个信誉度，信誉度高的 ESU 对融合决策的结果影响更大。基于异常值的方法可能会将合法用户完全排除在网络之外，因此基于信誉度的方法应用更加广泛。Paul 等^[84]利用模糊 C 均值聚类算法，基于信誉度将恶意 ESU 与诚实 ESU 隔离，直接将信誉度与通信权限挂钩，从系统层面限制了恶意用户的破坏能力。Nie 等^[85]提出了一种基于贝

叶斯学习的SSDF防御方案,通过离线和在线两种学习方式动态更新用户信誉度,从而有效识别恶意用户。进一步地,Paul等^[86]提出了一种基于DQN的抗SSDF频谱感知方案,在不需要预先计算用户信任值的情况下,直接从历史感知数据中学习并评估各ESU上报的能量值可信度,实现了比基于信誉度的贝叶斯方法更高的感知精度。

JA是无线网络中最常见的一种攻击,传统抗干扰方法包括基于序列的跳频扩频和直接序列扩频。这些方法具有固定传输模式,在面对动态干扰攻击时难以有效应对。机器学习技术则提供了更具自适应性的信道选择能力,最常见的策略是基于不同机器学习算法进行动态信道分配。JA场景可以使用随机零和博弈和马尔可夫决策过程(Markov decision process, MDP)进行建模。Wang等^[87]将CRN中的抗干扰问题建模为随机零和博弈,在博弈的每个阶段,ESU观察频谱可用性、信道质量和历史干扰信息,并决定应保留多少个信道用于消息传输以及如何进行信道切换,采用Minimax-Q算法学习最优防御策略。Gwon等^[88]提出竞争移动网络博弈模型,将抗干扰与主动干扰策略集成在一个随机博弈框架中,并采用Minimax-Q、Nash-Q和Friend-or-Foe Q等RL算法进行求解。研究表明,在集中式控制下Minimax-Q表现最优,在分布式场景下Friend-or-Foe Q更适用。Singh等^[89]指出,Minimax-Q学习属于离线策略且贪心,在抗干扰场景中可能并非最佳。因此Singh等^[89]采用状态-动作-奖励-状态-动作(state-action-reward-state-action, SARSA)和QV学习两种在线策略算法,在ESU的学习概率和累积平均奖励方面较Minimax-Q学习均有明显提升。为了加速学习过程并提升信道选择的性能,Thien^[90]等提出了一种名为TGACT的博弈论融合迁移学习框架,通过在博弈中迁移知识来优化RL训练。

与防御JA的方法类似,ESU可通过动态接入不同频段来避免EA。Houjeij等^[91]利用非合作博弈理论框架,分析了多个ESU与多个恶意窃听用户之间的竞争与交互,并设计了一种分布式安全信道选择算法,使双方能够通过分布式决策达到纳什均衡。该算法在保证安全性的同时,计算复杂度比标准学习算法降低86.5%。Subbulakshmi等^[92]提出了一种结合多级Stackelberg博弈和模糊逻辑的MDP-

Q学习的综合方案。该方案通过让ESU作为可信中继,在传输信息的同时利用部分功率发送干扰信号来对抗窃听,并利用Stackelberg对干扰机(领导者)和发射机(跟随者)的功率与时间分配进行优化,以最大化主、次链路的保密率并最小化功耗。同时,通过模糊MDP-Q学习框架来预测和规避窃听行为,最终实现物理层安全性的增强。

在防御DIA时,不能严格控制对数据库的访问,因为每个ESU都必须访问数据库才能启用频谱共享的过程。一种解决方案是向ESU提供混淆的信息而不是原始信息^[93],通过对原始信息进行可控的加工处理,使其难以直接使用,但同时保留其部分功能性价值。Vaka^[93]针对位置推理攻击,提出并比较了频谱接入系统中随机错误应答等多种混淆策略,在不严重影响频谱利用效率的前提下增强了MCU的位置隐私。进一步地,Clark等^[94]考虑了如何在保护MCU隐私与保障ESU频谱使用效率之间的权衡问题,采用SVM训练了一个具有固定计算资源的恶意用户,用来预测MCU的位置。基于恶意用户攻击,Clark等^[94]还设计了一种名为ARC的高效启发式策略,相比现有混淆方法,ARC在对频谱效率影响可忽略的情况下,将MCU隐私性提升50%。

6 潜在挑战与未来展望

本文提出了一种三层频谱管控分析框架,并介绍了6G内生智能频谱管控关键技术研究工作,包括基于机器学习的CSS技术与DSA技术、基于区块链和机器学习的频谱安全保障技术。尽管6G内生智能频谱管控在频谱资源高效利用方面展现出巨大潜力,但在实际部署与应用过程中仍面临着一系列亟待解决的潜在挑战。

1) 实时性约束。增强现实、虚拟现实、自动驾驶、工业互联网等6G应用对时延的要求极为苛刻,通常需要达到毫秒级甚至亚毫秒级。然而,现有基于机器学习的频谱管控算法,特别是复杂的DRL模型,往往依赖大量的离线训练与集中式推理,其决策时延难以满足这种极致的实时性需求。在大规模分布式网络环境中,多智能体之间的协同决策与信息交互将进一步加剧时延问题。因此,研究低复杂度的在线学习算法、设计高效的分布式决策架构,以及探索模型轻量化技术,是保障6G频

谱管控实时性能的关键方向。

2) 能效瓶颈。参与频谱管控的用频设备大多是能量受限的节点,但 6G 内生智能频谱管控本身引入了显著的能耗开销:CSS 需要大量 ESU 参与,频繁的信号采集与数据传输增加了额外的能耗;基于 DRL 的动态接入算法、智能合约等也会大量消耗计算资源与电量。若能耗问题得不到有效解决,将严重制约 6G 内生频谱管控关键技术能量敏感场景的大规模部署。未来研究可结合边缘计算技术或开发较低功耗的硬件与算法。

3) 干扰协调。随着 6G 向空天地一体化、通感算融合方向演进,频谱空间将同时容纳不同的异构无线系统,这些系统在服务需求需求和抗干扰能力上存在显著差异,这为干扰管理带来了新挑战。在 Underlay 模式下,即使 ESU 严格遵循发射功率限制,其累积干扰仍可能破坏对干扰容忍度较低的 MCU 的通信功能。此外,Interweave 的避让式接入策略虽然能够有效规避对 MCU 的干扰,但在密集部署场景中却容易造成 ESU 内部的接入拥堵和互相干扰。未来可考虑基于大模型来建模复杂异构网络中的干扰图谱,辅助制定跨系统协调策略。

4) 内生安全威胁。尽管机器学习技术能有效赋能频谱安全管控,但其模型自身却面临着严峻的安全威胁。在模型训练阶段,恶意用户可以发动数据投毒或后门攻击,向训练数据加入毒化样本,导致模型无法在测试阶段正常使用或存在潜在的后门。在测试阶段,恶意用户可以发动对抗样本攻击,向数据中加入不可觉察的轻微扰动,导致模型以很高的置信度输出错误的预测结果^[95]。未来可重点研究具备内在防御能力的可信 AI 模型架构。

5) 标准化缺失与监管壁垒。6G 内生智能频谱管控的广泛部署亟须健全的监管框架与标准化体系。当前不同国家对各频段的划分与使用政策存在差异,而频谱管控涉及跨国家、跨运营商之间的协调,各方利益博弈使协调时间跨度长、复杂性高。ITU 和 3GPP 等标准化组织应加速制定频谱管控的通用标准,建立国际认可的频谱管控协议与监管框架。同时,应平衡频谱资源利用效率与国家安全、公共利益之间的关系,保护在基础设施上进行了大量投资的主要用户的利益。

综上所述,尽管传统频谱管控技术多依赖静态分配、预定义规则和经典统计模型,缺乏一定的自

适应能力,但其优势在于实现简单、可靠性高、对计算资源要求低。智能频谱管控技术虽具备强大的环境感知与自主决策能力,却也面临实时性保障、计算开销大、能效与安全等挑战。未来的发展不应是二者之间的简单替代,而应走向协同与融合,在系统设计中结合传统方法的确定性与智能方法的适应性,根据具体场景需求构建混合式智能管控体系,最大限度地提升频谱资源的整体利用效率与智能化管理水平。

7 结束语

随着 5G 向 6G 的演进和未来用频设备的爆发式增长,频谱资源的高效、安全与智能化管控已成为未来通信系统发展的关键所在。本文系统梳理了频谱管控的研究现状,从未来频谱演进趋势出发,提出了一种面向 6G 的内生智能频谱管控三层分析框架,并基于该框架重点讨论了 CSS 与 DSA 中的机器学习方法,以及区块链和机器学习技术在频谱管控过程中保障安全与隐私方面的潜力,最后简单讨论了频谱管控中可能遇到的时效、节能、干扰管理、内生安全和标准化方面的挑战,指明了未来研究方向。

参考文献:

- [1] ITU-R. IMT traffic estimates for the years 2020 to 2030: M.2370[R]. 2015.
- [2] Cao M J, Wang Q, Du X J, et al. A fine-grained cross-chain spectrum sharing mechanism based on oracle[C]//Proceedings of the GLOBECOM 2023 - 2023 IEEE Global Communications Conference. Piscataway: IEEE Press, 2023: 5427-5432.
- [3] Arjoun Y, Kaabouch N. A comprehensive survey on spectrum sensing in cognitive radio networks: recent advances, new challenges, and future research directions[J]. Sensors, 2019, 19(1): 126.
- [4] Syed S N, Lazaridis P I, Khan F A, et al. Deep neural networks for spectrum sensing: a review[J]. IEEE Access, 2023, 11: 89591-89615.
- [5] Wang Y H, Ye Z F, Wan P, et al. A survey of dynamic spectrum allocation based on reinforcement learning algorithms in cognitive radio networks[J]. Artificial Intelligence Review, 2019, 51(3): 493-506.
- [6] Puspita R H, Shah S D A, Lee G M, et al. Reinforcement learning based 5G enabled cognitive radio networks[C]//Proceedings of the 2019 International Conference on Information and Communication Technology Convergence (ICTC). Piscataway: IEEE Press, 2019: 555-558.
- [7] Kaur A, Kumar K. A comprehensive survey on machine learning approaches for dynamic spectrum access in cognitive radio networks[J]. Journal of Experimental & Theoretical Artificial Intelligence, 2022, 34(1): 1-40.
- [8] 3GPP. Release 17 description; Summary of Rel-17 work items[R]. 2021.
- [9] 中华人民共和国工业和信息化部. 中华人民共和国无线电频率划分规定[R]. 2023. Technology of the People's Republic of China. Radio frequency alloca-

- tion regulation of the People's Republic of China[R]. 2023.
- [10] ITU-R WP5D. World Radiocommunication Conference 2023 (WRC-23) provisional final acts[R]. 2023.
- [11] 张海君, 陈安琪, 李亚博, 等. 6G 移动网络关键技术[J]. 通信学报, 2022, 43(7): 189-202.
- Zhang H J, Chen A Q, Li Y B, et al. Key technologies of 6G mobile network[J]. *Journal on Communications*, 2022, 43(7): 189-202.
- [12] ITU-R. Framework and overall objectives of the future development of IMT for 2030 and beyond[R]. 2023.
- [13] 中国联通. 中国联通6G网络内生智能白皮书[R]. 2025.
- China Unicom. China Unicom 6G network native AI white paper[R]. 2025.
- [14] Mitola J. Cognitive radio for flexible mobile multimedia communications[C]//Proceedings of the 1999 IEEE International Workshop on Mobile Multimedia Communications (MoMuC'99). Piscataway: IEEE Press, 1999: 3-10.
- [15] Haykin S. Cognitive radio: brain-empowered wireless communications[J]. *IEEE Journal on Selected Areas in Communications*, 2005, 23(2): 201-220.
- [16] Janu D, Kumar S, Singh K. A graph convolution network based adaptive cooperative spectrum sensing in cognitive radio network[J]. *IEEE Transactions on Vehicular Technology*, 2023, 72(2): 2269-2279.
- [17] Guimaraes F R V, Silva J M B D, Cavalcante C C, et al. Machine learning for spectrum sharing: a survey[J]. *Foundations and Trends in Networking*, 2024, 14(1/2): 1-159.
- [18] Umar R, Sheikh A U H, Deriche M. Unveiling the hidden assumptions of energy detector based spectrum sensing for cognitive radios[J]. *IEEE Communications Surveys & Tutorials*, 2014, 16(2): 713-728.
- [19] Song Z H, Gao Y, Tafazolli R. A survey on spectrum sensing and learning technologies for 6G[J]. *IEICE Transactions on Communications*, 2021, 104(10): 1207-1216.
- [20] Zang J W, Liu Q, He J, et al. On spectrum sensing for mmWave and THz beam-based communications[C]//Proceedings of the 2023 IEEE 97th Vehicular Technology Conference (VTC2023-Spring). Piscataway: IEEE Press, 2023: 1-6.
- [21] Xie H, Li D, Gu B W. Enhancing spectrum sensing via reconfigurable intelligent surfaces: passive or active sensing and how many reflecting elements are needed?[J]. *IEEE Transactions on Wireless Communications*, 2024, 23(10): 14940-14955.
- [22] Liu S, Shi Z P, He Z Q, et al. A robust RIS-enabled spectrum sensing algorithm for cognitive radio networks[J]. *IEICE Transactions on Communications*, 2025, 108(4): 493-501.
- [23] Ge J G, Liang Y C, Wang S, et al. RIS-assisted cooperative spectrum sensing for cognitive radio networks[J]. *IEEE Transactions on Wireless Communications*, 2024, 23(9): 12547-12562.
- [24] Coluccia A, Fascista A, Ricci G. Spectrum sensing by higher-order SVM-based detection[C]//Proceedings of the 2019 27th European Signal Processing Conference (EUSIPCO). Piscataway: IEEE Press, 2019: 1-5.
- [25] Vyas M R, Patel D K, Lopez-Benitez M. Artificial neural network based hybrid spectrum sensing scheme for cognitive radio[C]//Proceedings of the 2017 IEEE 28th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC). Piscataway: IEEE Press, 2017: 1-7.
- [26] Zhang J, Wu Y H. Likelihood-ratio tests for normality[J]. *Computational Statistics & Data Analysis*, 2005, 49(3): 709-721.
- [27] Saravanan P, Chandra S S, Upadhye A, et al. A supervised learning approach for differential entropy feature-based spectrum sensing[C]//Proceedings of the 2021 Sixth International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET). Piscataway: IEEE Press, 2021: 395-399.
- [28] Hu Q, Luo Z Q, Xiao W S. Supervised learning spectrum sensing method via geometric power feature[J]. *Electronics*, 2023, 12(7): 1616.
- [29] Krishnan G, Joshi N, Shankar H M B, et al. Eigenvalue-based spectrum sensing in cognitive radio networks using supervised learning[C]//Proceedings of the 2021 10th International Conference on Internet of Everything, Microwave Engineering, Communication and Networks (IEMECON). Piscataway: IEEE Press, 2021: 1-5.
- [30] Thilina K M, Choi K W, Saquib N, et al. Machine learning techniques for cooperative spectrum sensing in cognitive radio networks[J]. *IEEE Journal on Selected Areas in Communications*, 2013, 31(11): 2209-2221.
- [31] Sobabe G C, Song Y H, Bai X M, et al. A cooperative spectrum sensing algorithm based on unsupervised learning[C]//Proceedings of the 2017 10th International Congress on Image and Signal Processing, Bio-Medical Engineering and Informatics (CISP-BMEI). Piscataway: IEEE Press, 2017: 1-6.
- [32] Majumder S. A Gaussian mixture model method for eigenvalue-based spectrum sensing with uncalibrated multiple antennas[J]. *Signal Processing*, 2022, 192: 108404.
- [33] Khalek N A, Hamouda W. Intelligent spectrum sensing: an unsupervised learning approach based on dimensionality reduction[C]//Proceedings of the ICC 2022 - IEEE International Conference on Communications. Piscataway: IEEE Press, 2022: 171-176.
- [34] Khalek N A, Hamouda W. Unsupervised two-stage learning framework for cooperative spectrum sensing[C]//Proceedings of the ICC 2021 - IEEE International Conference on Communications. Piscataway: IEEE Press, 2021: 1-6.
- [35] Chávez Muñoz P D, Córdova Bernuy C D, Manco Vásquez J C. On experimental evaluation of unsupervised spectrum sensing[C]//Proceedings of the 21st LACCEI International Multi-Conference for Engineering, Education, and Technology (LACCEI 2023). Piscataway: IEEE Press, 2023: 389-393.
- [36] Khalek N A, Hamouda W. DeepSense: an unsupervised deep clustering approach for cooperative spectrum sensing[C]//Proceedings of the ICC 2023 - IEEE International Conference on Communications. Piscataway: IEEE Press, 2023: 1868-1873.
- [37] Pham T T H, Cho S. A review on reinforcement learning enabled cooperative spectrum sensing[C]//Proceedings of the 2023 International Conference on Information Networking (ICOIN). Piscataway: IEEE Press, 2023: 669-672.
- [38] Sutton R S, Barto A G. Reinforcement learning: an introduction[J]. *IEEE Transactions on Neural Networks*, 1998, 9(5): 1054.
- [39] Janu D, Singh K, Kumar S. Machine learning for cooperative spectrum sensing and sharing: a survey[J]. *Transactions on Emerging Telecommunications Technologies*, 2022, 33: e4352.
- [40] Lo B F, Akyildiz I F. Reinforcement learning-based cooperative sensing in cognitive radio ad hoc networks[C]//Proceedings of the 21st Annual IEEE International Symposium on Personal, Indoor and Mobile Radio Communications. Piscataway: IEEE Press, 2010: 2244-2249.
- [41] Jalil S Q, Chalup S, Rehmani M H. Cognitive radio spectrum sensing and prediction using deep reinforcement learning[C]//Proceedings of the 2021 International Joint Conference on Neural Networks (IJCNN). Piscataway: IEEE Press, 2021: 1-8.
- [42] Xu M D, Song X K, Zhao Y L, et al. Deep reinforcement learning-based RIS-assisted cooperative spectrum sensing in cognitive radio network[J]. *IEICE Transactions on Communications*, 2025, 108(4): 404-410.

- [43] Chen Z B, Xu Y Q, Wang H B, et al. Federated learning-based cooperative spectrum sensing in cognitive radio[J]. *IEEE Communications Letters*, 2022, 26(2): 330-334.
- [44] Yang B, Cao X L, Huang C W, et al. Federated spectrum learning for reconfigurable intelligent surfaces-aided wireless edge networks[J]. *IEEE Transactions on Wireless Communications*, 2022, 21(11): 9610-9626.
- [45] Zhang Y, Cai P X, Pan C Y, et al. Multi-agent deep reinforcement learning-based cooperative spectrum sensing with upper confidence bound exploration[J]. *IEEE Access*, 2019, 7: 118898-118906.
- [46] Lundén J, Koivunen V, Kulkarni S R, et al. Reinforcement learning based distributed multiagent sensing policy for cognitive radio networks[C]//*Proceedings of the 2011 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN)*. Piscataway: IEEE Press, 2011: 642-646.
- [47] Das A, Ghosh S C, Das N, et al. Q-learning based co-operative spectrum mobility in cognitive radio networks[C]//*Proceedings of the 2017 IEEE 42nd Conference on Local Computer Networks (LCN)*. Piscataway: IEEE Press, 2017: 502-505.
- [48] Zhao Q, Sadler B M. A survey of dynamic spectrum access[J]. *IEEE Signal Processing Magazine*, 2007, 24(3): 79-89.
- [49] Hatfield D N, Weiser P J. Property rights in spectrum: taking the next step[C]//*Proceedings of the First IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks*. Piscataway: IEEE Press, 2005: 43-55.
- [50] Weiss M B, Palida A, Murtazashvili I, et al. A property-rights mismatch approach to passive-active spectrum use coexistence[C]//*Proceedings of the 2021 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN)*. Piscataway: IEEE Press, 2021: 89-96.
- [51] Patil A, Iyer S, López O L A, et al. A comprehensive survey on spectrum sharing techniques for 5G/B5G intelligent wireless networks: opportunities, challenges and future research directions[J]. *Computer Networks*, 2024, 253: 110697.
- [52] Zhao Q, Krishnamachari B, Liu K Q. On myopic sensing for multi-channel opportunistic access: structure, optimality, and performance[J]. *IEEE Transactions on Wireless Communications*, 2008, 7(12): 5431-5440.
- [53] Liu K Q, Zhao Q. Indexability of restless bandit problems and optimality of whittle index for dynamic multichannel access[J]. *IEEE Transactions on Information Theory*, 2010, 56(11): 5547-5567.
- [54] Li H S. Multiagent-learning for aloha-like spectrum access in cognitive radio systems[J]. *EURASIP Journal on Wireless Communications and Networking*, 2010, 2010: 876216.
- [55] Wang S X, Liu H P, Gomes P H, et al. Deep reinforcement learning for dynamic multichannel access in wireless networks[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2018, 4(2): 257-265.
- [56] Li F, Zhu Y, Xu Y Y. Dynamic multi-channel access in wireless system with deep reinforcement learning[C]//*Proceedings of the 2020 12th International Conference on Advanced Computational Intelligence (ICACI)*. Piscataway: IEEE Press, 2020: 283-287.
- [57] Wang X Y, Teraki Y, Umehira M, et al. A usage aware dynamic spectrum access scheme for interweave cognitive radio network by exploiting deep reinforcement learning[J]. *Sensors*, 2022, 22(18): 6949.
- [58] Naparstek O, Cohen K. Deep multi-user reinforcement learning for distributed dynamic spectrum access[J]. *IEEE Transactions on Wireless Communications*, 2019, 18(1): 310-323.
- [59] Tan X, Zhou L, Wang H J, et al. Cooperative multi-agent reinforcement-learning-based distributed dynamic spectrum access in cognitive radio networks[J]. *IEEE Internet of Things Journal*, 2022, 9(19): 19477-19488.
- [60] Song Y F, Chang H H, Liu L J. Federated dynamic spectrum access through multi-agent deep reinforcement learning[C]//*Proceedings of the GLOBECOM 2022 - 2022 IEEE Global Communications Conference*. Piscataway: IEEE Press, 2022: 3466-3471.
- [61] Jalil S Q, Rehmani M H, Chalup S. A deep reinforcement learning approach to fair distributed dynamic spectrum access[C]//*Proceedings of the MobiQuitous 2020 - 17th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*. New York: ACM Press, 2020: 236-244.
- [62] Chang H H, Song H, Yi Y, et al. Distributive dynamic spectrum access through deep reinforcement learning: a reservoir computing-based approach[J]. *IEEE Internet of Things Journal*, 2019, 6(2): 1938-1948.
- [63] Rathee G, Jaglan N, Garg S, et al. A secure spectrum handoff mechanism in cognitive radio networks[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2020, 6(3): 959-969.
- [64] Bhattarai S, Vaka P R, Park J M. Thwarting location inference attacks in database-driven spectrum sharing[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2018, 4(2): 314-327.
- [65] Tan Y, Sengupta S, Subbalakshmi K P. Coordinated denial-of-service attacks in IEEE 802.22 networks[C]//*Proceedings of the 2010 IEEE International Conference on Communications*. Piscataway: IEEE Press, 2010: 1-5.
- [66] 张明, 徐国强. 区块链技术及其在无线电频谱管理中的应用潜力[J]. *中国无线电*, 2019(3): 59-61.
Zhang M, Xu G Q. Block chain technology and its application potential in radio spectrum management[J]. *China Radio*, 2019(3): 59-61.
- [67] 周盈君, 高音, 魏一然. 面向 6G 的区块链技术研究[J]. *信息技术*, 2025, 19(2): 38-44.
Zhou Y J, Gao Y, Wei Y R. Research on blockchain technology towards 6G[J]. *Information and Communications Technologies*, 2025, 19(2): 38-44.
- [68] Wang S, Sun C. Blockchain empowered dynamic spectrum sharing: standards, state of research and road ahead[J]. *IEEE Communications Standards Magazine*, 2023, 7(3): 72-80.
- [69] Baboi M. Security of consensus mechanisms in blockchain[J]. *Romanian Cyber Security Journal*, 2023, 5(2): 45-53.
- [70] Liang Y F, Lu C, Zhao Y P, et al. Interference-based consensus and transaction validation mechanisms for blockchain-based spectrum management[J]. *IEEE Access*, 2021, 9: 90757-90766.
- [71] Fernando P, Dadallage K, Gamage T, et al. Distributed-proof-of-sense: blockchain consensus mechanisms for detecting spectrum access violations of the radio spectrum[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2023, 9(5): 1110-1125.
- [72] Liu M J, Wu Q H, Hei Y M, et al. Blockchain-based licensed spectrum fair distribution method towards 6G-envisioned communications[J]. *Applied Sciences*, 2023, 13(16): 9231.
- [73] Roopa V, Pradhan H S. Blockchain oriented spectrum sharing in intelligent wireless networks[C]//*Proceedings of the 2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT)*. Piscataway: IEEE Press, 2023: 1-7.
- [74] Zheng S, Han T, Jiang Y N, et al. Smart contract-based spectrum sharing transactions for multi-operators wireless communication networks[J]. *IEEE Access*, 2020, 8: 88547-88557.
- [75] Zhang X Y, Zhao Y P. Smart contract-based distributed spectrum sensing for blockchain-enabled spectrum sharing[C]//*Proceedings of the 2022 IEEE 96th Vehicular Technology Conference (VTC2022-Fall)*.

- Piscataway: IEEE Press, 2022: 1-5.
- [76] Cuellar D, Sallal M, Williams C. BSM-6G: blockchain-based dynamic spectrum management for 6G networks: addressing interoperability and scalability[J]. IEEE Access, 2024, 12: 59643-59664.
- [77] Wu Q H, Wang W, Li Z G, et al. SpectrumChain: a disruptive dynamic spectrum-sharing framework for 6G[J]. Science China Information Sciences, 2023, 66(3): 130302.
- [78] Luo H X, Sun G, Chi C, et al. Convergence of symbiotic communications and blockchain for sustainable and trustworthy 6G wireless networks[J]. IEEE Wireless Communications, 2025, 32(2): 18-25.
- [79] Wang Q, Sun H J, Hu R Q, et al. When machine learning meets spectrum sharing security: methodologies and challenges[J]. IEEE Open Journal of the Communications Society, 2022, 3: 176-208.
- [80] Inamdar M A, Kumaraswamy H V. Accurate primary user emulation attack (PUEA) detection in cognitive radio network using KNN and ANN classifier[C]//Proceedings of the 2020 4th International Conference on Trends in Electronics and Informatics (ICOEI)(48184). Piscataway: IEEE Press, 2020: 490-495.
- [81] Muñoz E C, Pedraza L F, Hernández C A. Machine learning techniques based on primary user emulation detection in mobile cognitive radio networks[J]. Sensors, 2022, 22(13): 4659.
- [82] Dong Q, Chen Y, Li X H, et al. Explore recurrent neural network for PUE attack detection in practical CRN models[C]//Proceedings of the 2018 IEEE International Smart Cities Conference (ISC2). Piscataway: IEEE Press, 2018: 1-9.
- [83] Xu M D, Zhao Y L, Zhang R, et al. A reliable spectrum sensing method based on deep learning for primary user emulation attack detection in cognitive radio network[J]. IEEE Communications Letters, 2024, 28(3): 547-551.
- [84] Paul A, Choi K. Joint spectrum sensing and D2D communications in Cognitive Radio Networks using clustering and deep learning strategies under SSDF attacks[J]. Ad Hoc Networks, 2023, 143: 103116.
- [85] Nie G M, Ding G R, Zhang L Y, et al. Byzantine defense in collaborative spectrum sensing via Bayesian learning[J]. IEEE Access, 2017, 5: 20089-20098.
- [86] Paul A, Mishra A K, Shreevastava S, et al. Deep Reinforcement Learning based reliable spectrum sensing under SSDF attacks in Cognitive Radio networks[J]. Journal of Network and Computer Applications, 2022, 205: 103454.
- [87] Wang B B, Wu Y L, Liu K J R, et al. An anti-jamming stochastic game for cognitive radio networks[J]. IEEE Journal on Selected Areas in Communications, 2011, 29(4): 877-889.
- [88] Gwon Y, Dastangoo S, Fossa C, et al. Competing mobile network game: embracing antijamming and jamming strategies with reinforcement learning[C]//Proceedings of the 2013 IEEE Conference on Communications and Network Security (CNS). Piscataway: IEEE Press, 2013: 28-36.
- [89] Singh S, Trivedi A. Anti-jamming in cognitive radio networks using reinforcement learning algorithms[C]//Proceedings of the 2012 Ninth International Conference on Wireless and Optical Communications Networks (WOCN). Piscataway: IEEE Press, 2012: 1-5.
- [90] Thien H T, Vu V H, Koo I. A transfer games actor-critic learning framework for anti-jamming in multi-channel cognitive radio networks[J]. IEEE Access, 2021, 9: 47887-47900.
- [91] Houjeij A, Saad W, Bas,ar T. A game-theoretic view on the physical layer security of cognitive radio networks[C]//Proceedings of the 2013 IEEE International Conference on Communications (ICC). Piscataway: IEEE Press, 2013: 2095-2099.
- [92] Subbulakshmi P, Prakash M. Mitigating eavesdropping by using fuzzy based MDPOP-Q learning approach and multilevel Stackelberg game theoretic approach in wireless CRN[J]. Cognitive Systems Research, 2018, 52: 853-861.
- [93] Vaka P R. Security and performance issues in spectrum sharing between disparate wireless networks[D]. Virginia: Virginia Polytechnic Institute and State University, 2017.
- [94] Clark M, Psounis K. Optimizing primary user privacy in spectrum sharing systems[J]. IEEE/ACM Transactions on Networking, 2020, 28(2): 533-546.
- [95] 张思成, 张建廷, 杨研蝶, 等. 电磁频谱人工智能模型的对抗安全威胁综述[J]. 无线电通信技术, 2024, 50(1): 1-13.
- Zhang S C, Zhang J T, Yang Y D, et al. Review of adversarial security threats to electromagnetic spectrum artificial intelligence models[J]. Radio Communications Technology, 2024, 50(1): 1-13.

[作者简介]



王先梅 (1974-), 女, 山东烟台人, 博士, 北京科技大学副教授, 主要研究方向为信号处理、机器学习。



任语铮 (1995-), 女, 北京人, 博士, 北京科技大学副教授, 主要研究方向为6G移动通信、车联网、工业互联网。



姜天宇 (2001-), 男, 河北承德人, 北京科技大学硕士生, 主要研究方向为6G移动通信、频谱资源管控。



张海君 (1986-), 男, 辽宁朝阳人, 博士, 北京科技大学教授、博士生导师, 主要研究方向为6G移动通信、人工智能与无线网络、卫星通信、机器学习与大数据等。



马旭 (1996-), 男, 山东菏泽人, 北京科技大学博士生, 主要研究方向为6G移动通信、空地一体化网络。