



世界无线局域网应用发展联盟  
WLAN Application Alliance



Network Innovation and  
Development Alliance  
全球固定网络创新联盟

# AI新联接 赋能新工业革命 研究报告



媒体合作 : [contact@waa-alliance.org](mailto:contact@waa-alliance.org)

工作机会 : [contact@waa-alliance.org](mailto:contact@waa-alliance.org)

业务合作 : [contact@waa-alliance.org](mailto:contact@waa-alliance.org)

官方网站 : [www.waa-alliance.com](http://www.waa-alliance.com)

2025年5月

# 版权声明

《AI 新联接赋能新工业革命研究报告》（以下简称“研究报告”）由世界无线局域网应用发展联盟 (World WLAN Application Alliance, WAA) 和全球固定网络创新联盟 (Network Innovation and Development Alliance, NIDA) 联合创作，著作权归双方共同所有，并受法律保护。转载、摘编或利用其它方式使用本研究报告文字或者观点的，应注明“来自世界无线局域网应用发展联盟 (World WLAN Application Alliance, WAA) 全球固定网络创新联盟 (Network Innovation and Development Alliance, NIDA)””。违反上述声明者，WAA 和 / 或 NIDA 将追究其相关法律责任。

# 免责声明

本文档可能含有预测信息，包括但不限于有关未来的新技术、新业务、新产品等信息。由于实践中存在很多不确定因素，可能导致实际结果与预测信息有很大的差别。因此，本研究报告信息仅供参考，不构成任何要约或承诺，用户应自行判断并承担使用风险。WAA、NIDA 及参与编写单位不对您在本文档基础上做出的任何行为承担责任，WAA 和 / 或 NIDA 有权随时调整、修改上述信息而无须另行通知。

# 参与编写单位

中移（杭州）信息技术有限公司  
华为技术有限公司  
中兴通讯股份有限公司  
新华三技术有限公司  
锐捷网络股份有限公司  
海思技术有限公司  
深圳市朗力半导体有限公司  
烽火通信科技股份有限公司  
TÜV 莱茵  
深圳市极致汇仪科技有限公司  
瑞晨微电子（苏州）有限公司

# 主要撰稿人

（排名不分先后）

赵航斌、苏畅、谢旭东、许一骅、李峰、李彦淳、徐帆、廖倩、吴徐明、赵望生、石华平、岳华伟、张波、王波、张耀东、程永椿、石振中、朱丽花、钟科、徐方鑫、黄启圣、王子晟、钱玉蓉、刘凯林、孙旭红、曹博、李云、陈金花、杜波、李巍、王戈、刘大兴、姚峰、樊智超、陈之雄、张弢

# 目录

## 引言

01

## 第一章 AI 在 WLAN 网络中的核心价值

02

## 第二章 关键技术及应用场景：AI 如何优化 WLAN 体验

04

## 第三章 AI 与未来 WLAN 的空口协同

14

## 第四章 挑战与未来方向

21

## 结论

24

# 第一章

# AI 在 WLAN 网络中的核心价值

## 1.1 AI 技术介绍

AI技术通过模拟人类智能，使机器具备感知、学习、推理和决策能力，当前，以机器学习（Machine Learning）为代表的AI技术，凭借其从海量数据中挖掘规律、优化决策的能力，为WLAN网络的高效运维、性能优化、安全保障、资源管理和体验提升提供了新的解决方案。

AI技术的核心范式，包括监督学习（Supervised Learning）、无监督学习（Unsupervised Learning）、强化学习（Reinforcement Learning）、生成式AI（Generative AI）等。相应的特点如下：

- **监督学习：**作为应用最广泛的技术分支，监督学习通过分类与回归预测模型，可精准预判网络变化，优化决策。例如，基于接收信号强度（RSSI）的时序预测，可辅助设备漫游决策，优化切换时延与稳定性。
- **无监督学习：**通过聚类与降维技术，可高效处理高维度、无标签数据。例如，对信道状态信息CSI（Channel State Information）进行压缩与特征提取，降低空口传输开销，提升频谱利用率。对无线环境的干扰和攻击进行识别，提升安全和隐私保护等。
- **强化学习：**以动态优化为目标，强化学习通过智能体与环境交互实现策略迭代，应用于无线资源管理（RRM）、网络参数自适应调整等领域，显著提升复杂环境下的网络韧性。
- **生成式AI：**以大语言模型（LLM）为代表的生成式技术，可重构人机交互模式，例如通过自然语言指令实现网络配置自动化，降低运维门槛。

AI技术的分类方式，还包括传统机器学习和基于神经网络的深度学习（Deep Learning）。在实践中，这两类方式可优势互补。传统机器学习一般基于明确的统计推断，稳定性和可解释性较好，对算力要求较低，但往往模型能力受限，擅长处理数据简单、数据量较少的问题。深度学习则有强大的非线性拟合能力，擅长处理数据量大的复杂问题，对训练数据和算力资源的要求较高。

## 引言

基于人工智能的无线局域网（AI WLAN）通过深度融合人工智能（AI）与无线网络技术，为新工业革命提供了关键的基础无线局域网支持。它通过智能化、自适应和高效的数据传输，可显著提升社会生产力，带来社会生产、生活效率的提升。WLAN技术的持续演进，WLAN日益普及至人们的工作、生产、生活等各方面应用中，无线网络承载的数据量呈指数级增长，传统静态管理方式已无法满足高密度、低延迟、高可靠性的需求。AI的引入，使WLAN网络能够实时感知环境变化、预测干扰并动态优化资源分配，大幅提升用户体验。WLAN作为信息网络中的毛细血管，其AI智能化是新工业革命的关键支撑。

本研究报告探讨AI在WLAN网络中的关键技术，并结合实际用例，展示AI如何解决干扰抑制、信道波动、负载均衡等核心问题。

## 1.2 AI 对 WLAN 的价值

从较为传统的K-means、决策树、概率图模型方法，到新兴的基于神经网络的DRL、Transformer、LLM方法，可帮助WLAN解决各方面的问题。下表列出了一些AI技术在WLAN应用的探索方向。

表1 AI技术在WLAN中的应用方向

AI 技术	应用领域
K-means	模式识别, 如无线环境分类
Decision Tree 决策树	模式识别, 如设备健康度分析, 覆盖空洞识别
Probabilistic Graphical Models 概率图模型	闭环问题解决, 问题根因分析
Mutual Information 互信息	无线信道特征工程
ARIMA 自回归整合移动平均模型	WLAN 设备日志时间序列异常分析
Logistic Regression 逻辑回归	WLAN 设备健康度分析
Bayesian inference 贝叶斯推理	模式识别, 如异常终端分析; WLAN AP 点位规划
LSTM 长短时记忆网络 RNN 循环神经网络	信道环境预测, MCS 预测
DRL 深度强化学习	无线参数调优, 如 RRM 参数调整
Transformer 变换器网络	预测分析, 自然语言处理
KNN k 近邻 (算法)	无线算法动态阈值生成
CNN 卷积神经网络	干扰检测, 无线路损仿真
LLM 大语言模型	精准理解人类意图, 提供规划, 运维, 安全, 问题定位的辅助分析及策略支持

这些 AI 技术（如机器学习、深度学习、强化学习）为 WLAN 网络带来以下核心优势：

- **实时优化**：动态调整信道、功率、调制方式以应对环境变化。
- **干扰抑制**：识别并规避同频 / 邻频干扰，提升信噪比（SNR）。
- **性能预测分析和处理**：通过历史数据分析预测网络拥塞风险，并作预见性处理。
- **可靠性提升**：异常检测，可靠性增强
- **新业务**：WLAN 感知

## 第二章

# 关键技术及应用场景： AI 如何优化 WLAN 体验

在网络通信领域，AI 的智能化特性为 WLAN 的体验优化提供了全新思路——通过实时学习网络状态、预测用户行为并动态调整资源配置，AI 能够显著提升 WLAN 的速率、稳定性和覆盖效率。

AI 可赋能 WLAN 从物理层到 MAC 层的全面提升。在物理层，AI 可提升应对信道干扰和无线信号传播条件变化的能力，减小 CSI 信息传输的开销，提升传输参数选择的准确度。在 MAC 层，AI 可提升对业务需求的估计、对动态流量的预测，实现动态的链路管理和优化的信道接入和资源调度，并节省 WLAN 网络能耗。在网络控制和管理层面，AI 可简化人对网络设备的操控。

## 2.1 干扰检测与抑制

在密集部署场景，大量 WLAN 设备共享 2.4GHz/5GHz 频段，导致 WLAN 频谱严重干扰。

### AI 解决方案：

- **干扰检测**：
  - 干扰类型和程度判断：收集大量正常和干扰状态下的信号数据作为训练集，使用如支持向量机（SVM）、决策树等算法进行训练，建立干扰检测模型，实时判断当前是否存在干扰以及干扰的类型和程度
  - 干扰混合小模型：以时域干扰个数 & 信号强度、频域干扰带宽 & 信号与干扰加噪声比值（SINR）、空域干扰方向 & 用户 MAC 地址等多维信息作为入参，采用 CNN 卷积神经网络，自动提取 WLAN 信号的特征，建立一个系统的干扰模型
- **性能增强**：
  - 深度学习的信道分配：利用深度学习算法，如深度神经网络（DNN）或卷积神经网络（CNN），根据环境中的干扰情况、用户分布、业务需求等多维度信息，自动学习并优化 WLAN 信道的分配。模型可以将环境特征作为输入，输出最优的信道分配方案，以避免干扰并提高频谱利用率
- **强化学习的功率控制**：通过强化学习算法，让 WLAN 智能体（如接入点 AP）与环境进行交互学习。智能体根据当前的干扰状态和自身的功率控制策略，采取不同的发射功率动作，然后从环境中获得奖励反馈（如通信质量的提升或干扰的降低）。通过不断地学习和优化，智能体可以找到最优的功率控制策略，在保证通信质量的前提下，降低对其他设备的干扰。

- 人工智能辅助的波束赋形：利用人工智能算法，如机器学习中的线性回归、岭回归等算法，根据环境中的干扰源位置、信号传播特性等信息，计算出最优的波束赋形向量。通过调整天线的发射波束方向，将信号集中指向目标用户，同时抑制对干扰源方向的信号发射，从而提高信号质量并减少干扰。

#### 应用场景/用例：

在密集办公或家居环境中，存在较多的WLAN设备干扰时，通过AI WLAN实现用户网络体验速率提升。

## 2.2 链路自适应

无线信道受多径效应、人体 / 障碍物遮挡、手持终端晃动和移动等影响，信号质量波动剧烈。

#### AI 解决方案：

##### • 信道感知

- 信道波动分类：把采集到的信道特征当作输入，例如信号强度、相位、多普勒频移等，对 SVM 模型进行训练，将信道状态划分成稳定、轻度波动、重度波动等类别。高维空间里找出最优分类超平面，进而实现对信道波动的准确分类。
- 信道波动判决：以信号强度、信噪比、多径时延扩展等多个信道特征，构建多个决策树构成的集成学习模型。以此提高信道波动检测的准确性和稳定性，有效处理特征之间的相互作用，减少过拟合现象。

##### • 性能增强

- 基于深度学习的 MCS 预测：利用深度学习模型（如 CNN、LSTM 等）对信道状态进行预测，根据预测结果自动选择合适的调制与编码方案。
- 基于强化学习的 MCS 选择：通过强化学习算法，智能体根据当前的信道状态和传输效果，不断调整 MCS。智能体在每次决策后，根据接收端反馈的误码率、吞吐量等指标获得奖励，通过不断学习和优化，找到最优的 MCS 调整策略，提升空口性能。
- 基于 AI 的波束跟踪：在用户终端移动的情况下，利用 AI 技术实现波束的实时跟踪。通过对终端移动轨迹的学习和预测，以及对信道变化的快速响应，智能体可以及时调整 WLAN 信号的 MIMO(Multiple Input Multiput Output) 波束成形方向和形状，确保波束始终准确地指向移动中的终端，减少信号中断和质量下降的情况。

#### 应用场景/用例：

在复杂办公或家居环境中，存在人走动/穿过，或手持手机晃动/移动时，通过AI WLAN实现用户网络体验速率提升。

## 2.3 物理层参数自适应

实时业务的需求在动态、复杂的无线环境下难以满足。传统WLAN速率选择算法（如基于信号强度，历史丢包率或少量数据探测的吟游诗人算法）难以应对动态复杂的无线环境，有以下问题：

- 次优速率选择：静态阈值无法适应信道干扰等实时变化，易选择过高（频繁重传）或过低（浪费带宽）的速率。
- 高延迟与抖动：频繁速率切换或重传会增大端到端延迟。
- 选择过程效率低下：随机采样以及标准协议演进带来的可选物理层发射参数集膨胀导致经典速率面临的寻优空间大，参数选择过程收敛慢，影响实时业务（如视频通话、VR）。

#### AI解决方案：

##### • 环境感知与特征提取：

- 将速率选择建模为马尔可夫决策过程（MDP），通过Q-learning、DQN等算法训练智能体：
  - 状态（State）：当前信道质量、设备负载、干扰水平等
  - 动作（Action）：选择最佳发射参数组合，包括MCS, GI, NSS等
  - 奖励（Reward）：最大化吞吐量、最小化延迟或丢包率。

- 通过持续交互学习，智能体可快速适应动态环境，相关进展包括DARA(Data-driven Algorithm for Rate Adaptation)算法等。

##### • 联邦学习(FL)协同优化：

- 在多AP场景中，通过FL联合训练全局模型，共享局部经验（如信道占用模式），避免单节点决策的局部最优问题。

AI驱动的速率选择算法通过实时感知-决策-优化闭环，显著提升WLAN的可靠性、效率和适应性，尤其适用于动态、密集或高实时要求的业务场景。

#### 应用场景/用例：

家庭网络智能抗干扰，智能家居设备受微波炉、蓝牙间歇性干扰。通过在线学习模型识别干扰周期，在干扰峰值期主动降速，平稳期升速，提升平均吞吐量。

## 2.4 多链路负载均衡与资源分配

在 AP 多链路运行（MLO）场景中，传统 WLAN 依赖 RSSI（信号强度）将用户关联到链路，存在负载不均的问题。此外，网络中多个设备的同时接入以及带宽需求和流量模式的波动，为多链路管理带来进一步挑战。AI 技术的引入能够帮助优化多链路的负载均衡和资源分配，提升用户体验。

#### AI 解决方案：

##### • 聚类分析用户需求：

- 通过分类器或聚类算法（例如 K-means）将用户按业务类型（视频、IoT、游戏）分组，分配不同优先级。AI 系统可以实时监控各链路上的网络使用情况，包括带宽需求、流量类型和设备的工作负载。通过机器学习和深度学习，AI 能够识别不同设备和应用的流量模式，并预测未来的带宽需求，从而优化流量的分配。例如，AI 可以自动识别视频流、游戏、浏览网页和下载等不同类型的流量，通过流量到链路映射（TTLM）将高优先级应用（如视频通话或高清视频流）映射到指定链路上，并分配更多带宽。

##### • 动态带宽分配：

- 深度学习模型等可预测流量高峰，提前调配各链路资源。基于 AI 的网络多链路负载均衡与资源分配技术可以通过动态调整家庭网络中的带宽和流量，确保每个设备根据优先级和需求获得适当的资源。AI 可以根据链路质量和当前网络状况自适应调整路由，避免网络拥塞，确保用户的各类设备和应用的流畅运行。
- 当网络中的多个链路（如 2.4GHz 和 5GHz 的 WLAN 链路、甚至有线连接）都在使用，AI 系统可以根据实时的网络状况和不同链路的负载，智能地将流量分配到各个链路上，从而避免某个链路的过度拥塞。

**应用场景/用例：**通过AI预测流量并负载均衡，确保每个房间的延迟<10ms，或保障重点业务房间的吞吐、延迟。在家庭网络中，多个智能设备同时连接至网络。假设家庭中有一个智能电视正在播放4K视频流，一个家庭成员正在进行高清视频通话，另一个成员正在进行在线游戏，其他设备则在浏览网页或下载文件。传统的网络链路管理方法可能无法有效应对这种多设备、大流量的情况，导致某些应用（如视频通话或游戏）受其他背景流影响，出现卡顿或延迟。通过引入基于AI的多链路负载均衡系统，AI能够实时监控各个设备的带宽使用情况，并根据优先级自动选择链路并调整流量分配。例如，当智能电视播放高质量视频时，AI可以将其业务映射至低负载链路并为其分配更多带宽，确保视频播放流畅，同时减少对其他低带宽应用（如浏览网页）的影响，提升用户的整体体验。

## 2.5 基于 AI 的业务调度优化策略

WLAN网络的体验是一个系统性问题，全链路的调度策略都会一定程度上反映在WLAN体验上。目前较为常见的WLAN组网形式包括单台WLAN设备、FTTR、AC+AP等，其中FTTR组网如下图所示。局端到主网关及主从设备间一般采用PON组网，而PON网络现有的DBA调度策略通常是由ONU先申请再由OLT进行分配的方式确定，未考虑无线空口因素，使调度策略缺乏全局考虑，不能针对全链路网络状态进行预判和制定针对性的渐进优化策略，进而造成链路资源浪费和网络的进一步恶化。

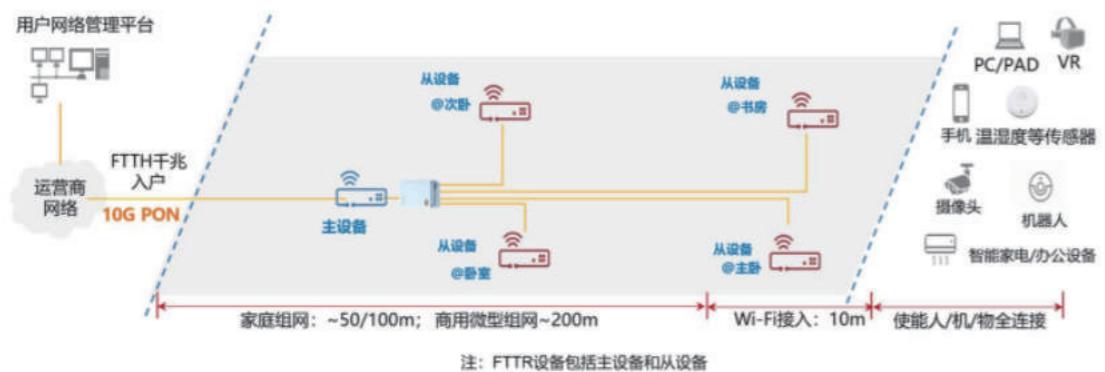


图 1 典型 FTTR 组网图示

### AI解决方案：

- **基于AI预测的光与空口联合业务保障策略：**
  - 全链路流量收集与预测：收集历史时间段全链路的流量大小、业务模型信息，作为训练集数据，使用如SVM、决策树、卷积神经网络等算法进行训练，建立光纤-无线业务流量预测模型，实时预测未来一定时间内光纤和无线链路上的流量和业务规模。
  - 用户数量预测：用户数量变化不仅影响空口调度，也考验分配光链路资源的调度算法是否合理。采用线性回归、决策树等算法，对历史用户数量分析，得到未来用户数量的预测值。并提供覆盖整网的各个ONU下用户数量的预测和趋势。
  - 空口质量预测与光路策略补偿：网络链路的各个节点都会影响终端用户使用体验，但网络链路并不是所有节点都能调优，或部分节点已调到最优。可以建立WLAN环境与光链路调度的联动机制，当某ONU或某区域空口环境恶化到一定程度后，通过光链路调度优化来补偿用户使用体验。采集用户网络各处的连接质量，并通过时间序

列分析等算法获得未来时间的用户网络质量模型。当预测到空口即将出现质量变差（如重传、丢包、高时延等）问题时，在光链路调度策略选取更进取的网络保障目标。基于预测的光与空口联合调度：相比于传统的“先申请后分配”算法，根据AI预测的业务模型和网络目标，再配合对无线空口质量的预测，主动提前指导光链路调度动态调整。通过预测和动态调整策略的方式，减少网络全链路的丢包和时延，并一定程度上减少固定分配带来的带宽浪费，使策略更加贴近现网实际流量需求，提升无线用户的用网体验。

### 应用场景/用例：

在流量、终端数、业务等存在周期潮汐场景（如小饭馆、商铺等），以及上行链路较长（如FTTR、长距离全光组网等）时，通过基于AI的上行链路调度策略优化，提高网络与实际业务的适应性；通过主动提前优化，提升网络优化的时效性；在高峰期，提升整网的吞吐量。

## 2.6 WLAN 感知

WLAN感知主要用于运动检测、目标识别、定位与跟踪等。常见的运动检测包括人体入侵检测、跌倒检测等。更精细运动检测，包括呼吸心跳等生物量检测，及手势识别等。WLAN感知可以根据CSI指纹实现人员识别认证。此外，定位和跟踪也一直是WLAN感知的研究热点，应用范围涵盖室内室外导航。高准确度是这些应用中非常具有挑战性的目标。以检测人员存在应用为例，动态环境（如风扇转动、窗帘飘动、宠物运动等）、无线干扰以及相邻房间或其他楼层的运动均会导致入侵/存在检测的误判。此外，人体静止不动时的CSI与高斯噪声下主导的空房间CSI特征相似，容易将有人误判为无人。基于AI进行人类行为检测、人类健康检测、构建虚拟数字空间、安全检测等方面有独特优势。

### AI解决方案：

- **人员活动感知**

基于LSTM、Transformer等感知算法，可以对一段时间内的动态RSSI、CSI等无线信号进行特征提取和分类，从而更加精准的刻画环境特征从而判断是否有人员进入，跌倒等情况发生。

  - 数据集构建：在无线通信的过程中，通过同步采集并标识不同人类活动场景下的CSI的数据，包括无人，有人行走，站立，躺倒等场景，形成模型训练数据集。
  - 模型训练：基于高质量训练数据和LSTM等AI算法模型，可以把无线信道的静态特征和动态特征结合，更加精准可靠的感知不同的人员活动类型。通过通信过程对不同场景、不同时段的数据进行高效采集和模型训练微调，可持续提升AI感知的场景适应性和准确性。用卷积神经网络（CNN）提取动态环境、无线设备干扰与人体运动特征。通过CSI、雷达波形后的特征差异。将波形数据预处理为二维矩阵后输入模型，经卷积、池化操作提取关键特征。通过样本训练，使CNN精准识别波形差异，过滤噪声信号，提升感知准确度。

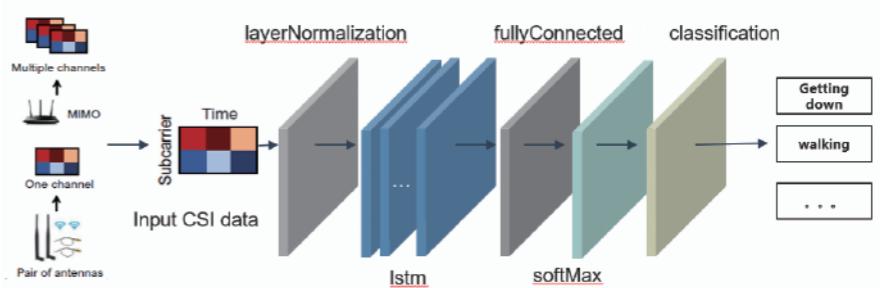


图 2 基于 LSTM 的人类行为分析

### • 呼吸信号感知

呼吸时胸腔起伏会引起 CSI 信号波动。利用 RNN (GRU (门控循环单元)) 处理感知波形，捕捉人体呼吸引起的胸腔起伏所产生的微小周期性变化。GRU 通过更新门和重置门的简化结构，能够有效保留与呼吸相关的时间依赖特征，同时减少计算复杂度和资源消耗。它能够滤除随机噪声或非周期性干扰，专注于微弱信号中的呼吸特征，从而识别出空间中是否存在静止的人体状态。

### • 发射功率及感知灵敏度调优

基于 DDPG (深度确定性梯度) 强化学习算法，将当前空间大小、邻居 AP 信息、误判次数 (来源于用户的反馈)、建筑障碍物材质厚度、用户通信体验等信息作为状态输入，把发射功率调整比例及感知灵敏度调整系数设为动作输出。以误判次数减少为正奖励、用户通信体验下降、误判增加或信号覆盖不足为负奖励构建奖励机制，将状态数据预处理后输入模型，经样本训练，使 DDPG 模型能够精准识别不同环境状态下的最优动作，自适应调整发射功率或感知灵敏度，有效过滤因信号穿透产生的干扰，降低错误检测率，在保障用户基本通信体验的同时提升 WLAN 感知系统的准确性。

### • 多设备融合感知

尽管 AI+CSI 能够实现运动感知，但面对建筑物遮挡、复杂电磁环境等场景时，可能无法实现精准感知。FTTR 架构下，从网关通过分支光纤与主网关连接，主网关配置有业务模块、光纤感知模块、无线信号感知模块、AI 融合算法模块。其中，业务模块实现通信业务，光纤感知模块通过分支光纤采集光纤散射光信号的强度与相位，无线信号感知模块采集 CSI 信号，AI 融合算法模块将光纤散射信号和 CSI 信号特征融合解析，实现对外界环境的感知。主网关的模块配置也可根据资源情况部署在从网关上。

#### 应用场景 / 用例：

- AI 算法赋能 WLAN 感知技术，使其从通信网络升级为智能环境感知平台，推进感知相关应用在家庭、园区、酒店场景的落地，赋予 WLAN 网络新的价值。
- 在一个存在外界设备和人员干扰的测试环境下，基于 LSTM 模型可实现人员进入的检测，准确度可以达到 93% 以上，在酒店、家庭等环境下，可在能较好保护用户隐私的前提下，提升安全保护和健康监测能力。

## 2.7 绿色节能

在传统 WLAN 网路中，节能措施往往以静态配置为主，如定时关闭部分模块、降低链路速率等。这种方式缺乏灵活性，难以动态适应网络负载变化，往往以牺牲性能或 QoS 为代价，节能效果有限。

#### AI 解决方案：

##### 业务环境感知

- 业务特性：AI 模块通过对数据包内容、流量特征、端口活跃情况等进行实时分析，利用深度学习模型（如 CNN、RNN 等）或传统机器学习模型（如决策树、SVM 等）实现对业务类型和负载强度的识别。并通过对下一时间段业务的预测以及对 SLA 的要求，基于业务特性来进行无线传输节能的设计。
- 网络环境：AI 系统通过训练好的模型感知设备运行环境、用户活动状态和物理网络状态，动态调整设备节能模式。并分析用户行为模式与历史流量，在低流量预测时段提前让 AP 或链路进入低功耗模式或休眠模式，提高能源效率。

### 动态节能措施

- 按需供能：根据业务类型，决定是否启用高速传输通道或保持低功耗运行。在不影响业务 QoS 需求的前提下，自适应调节发射功率、选择最优 MCS、优化调度资源提升链路质量和频谱利用率，实现能效最大化。
- 智能感知与自适应调整：运用 AI 技术，通过路由器（FTTR 架构下，可以是主网关）采集的设备数据构建设备状态数据库，数据库涵盖路由器的使用情况（如连接设备数量、无线保真 WLAN 流量数据、局域网 LAN 口流量）、网络环境变化（信号干扰程度、信道质量）、设备状态数据、设备功耗等信息。路由器中（FTTR 架构下，可以是主网关上部署）的 AI 模型对设备状态数据库中的数据进行分析，生成节能控制指令并发送至对应的设备。通过持续学习用户日常使用路由器的行为模式，AI 模型能够精准分析出设备在不同时间段的使用频率和业务需求。当检测到设备处于低活动状态时，自动将路由器调整到低功耗模式；而在高活动需求时，自动唤醒或恢复正常性能，有效避免不必要的能源消耗。在园区场景下，FTTR 主网关作为数据中枢，持续采集各从网关的无源光网络 PON 口流量数据、WLAN 流量数据、LAN 口流量，同时监控路由器设备状态、功耗及告警信息，构建覆盖全园区的设备状态数据库。考虑到园区网络节点众多、数据传输量大的特性，主网关内置经过特征降维和模型压缩的轻量化 AI 模型，确保在高效处理海量数据的同时，降低自身运行能耗。AI 模型对数据库进行深度分析，针对园区多区域、多业务的复杂场景制定节能策略。
- 智能预测与智能唤醒：借助 AI 对路由器历史使用数据的分析，预测用户未来的使用需求。例如，依据用户每天固定的上网习惯，在用户常用上网时间段前，提前将路由器从待机模式唤醒并恢复正常工作状态，确保用户使用时网络能快速响应；在用户长时间未使用路由器时，自动进入深度待机状态，进一步降低能耗。
- 设备间协同节能：AI 使路由器能够与家庭中的其他智能设备（如智能灯光、空调、电视、智能插座连接的家电等）进行联动。在家庭无人时，通过与智能门锁或其他传感器的信息交互，检测到家庭成员全部外出，自动关闭或降低 WLAN 空口发射功率，仅保留 IoT 设备最低功耗模式；在园区 AC+AP 结构或者在 FTTR 架构下，主网关将 AI 模型对设备状态数据库中的数据进行分析，生成节能控制指令并发送至从网关，关闭部分从网关以及高能耗设备（如 NAS、智能电视待机）。在夜间低流量时，根据网络使用率降低的情况，自动让 WLAN AP 进入低功耗模式，降低信号强度或关闭 5GHz 频段；主网关降低 CPU 频率，减少后台处理任务，并通过定时调度进入夜间节能模式，早晨自动恢复正常模式。在低负载应用场景下，按流量阈值调节路由器功耗，如降低 WLAN 空口传输功率，其他 WLAN AP 休眠，仅主网关维持基本连接，同时仅开启低功耗 IoT 专属信道（如星闪、Thread、Zigbee、BLE）。

#### 应用场景 / 用例：

引入 AI 后，WLAN 网络设备可通过业务感知与环境感知，实现更精细化、智能化的 ECO 节能控制，实现超越传统 ECO 模式的节能。

## 2.8 简化对网络的操控

无线网络局点，尤其是企业级的网络局点，涉及的网络设备极多，网络指标和可配置参数也繁多复杂。无线网络本身存在不可见、不确定的特性。IT 人员运用传统运维手段，需要繁琐的问题复现和问题定位流程，分析问题困难；网络设备的配置和人机交互也需要很专业的知识储备，对用户的要求较高；易用性也比较差。

## AI解决方案：

## • 网络故障感知 / 分析 / 排障：

- 终端体验分类：实时监控终端的丢包率，RSSI等无线网络核心指标，通过分类模型（如随机森林、神经网络等），对终端的使用体验进行分类，实现快速报障和无人设备的自动报障。
- 故障根因分析：针对故障收集网络数据，结合分类模型等算法，发掘故障背后的根因，帮助运维人员快速排障。

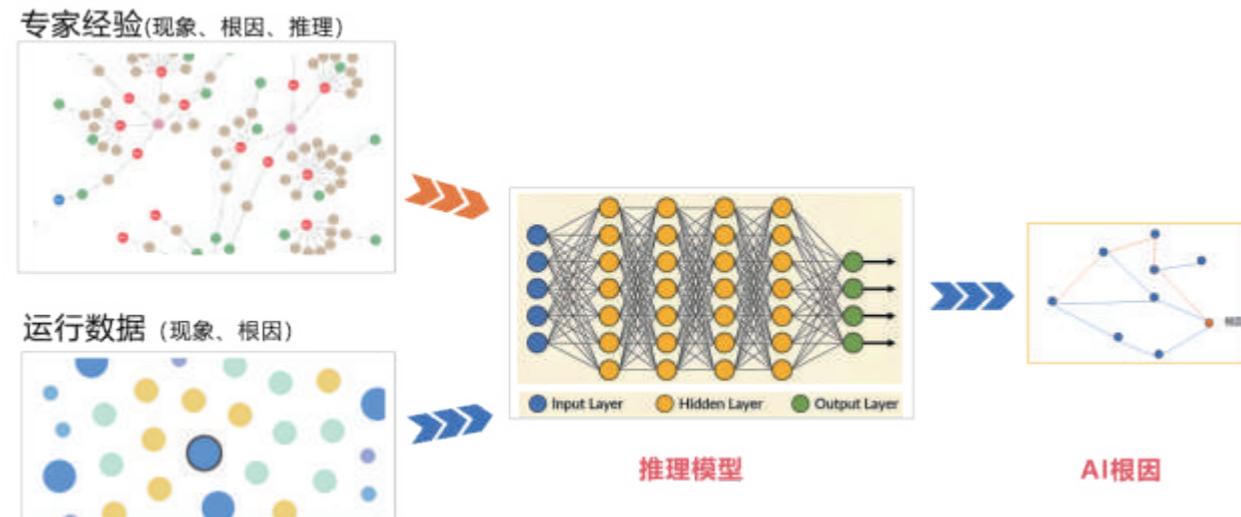


图3 基于AI排障的无线问题根因分析

- **语音控制**：在网关以及路由器等网络设备中嵌入AI算法，实现语音输入控制功能，可以方便的调整WLAN配置的参数，再通过WLAN通道下发控制指令给连接到WLAN网络的终端设备，实现语音命令来控制网络设备的目的。这种交互方式更加自然和便捷，可以提高用户体验。
- **机器学习**：AI可以通过机器学习算法来优化网络设备的性能和安全性。例如，AI可以根据历史数据预测未来的流量趋势，并提前调整网络设备的配置；或者根据异常行为检测算法发现潜在的安全威胁，并及时采取措施。
- **虚拟助手**：AI可以实现虚拟助手功能，为人们提供个性化的服务和支持。例如，在遇到问题时，虚拟助手可以帮助人们快速定位问题并提供解决方案；或者在需要技术支持时，虚拟助手可以为人们提供远程协助和支持。
- **预测性维护**：AI可以通过预测性维护算法来预测网络设备可能出现的问题，并提前采取措施。这种维护方式可以大大减少故障率和停机时间。
- **智能推荐**：AI可以根据用户的历史行为和偏好来推荐相关的服务或产品。这种推荐方式可以帮助人们更好地满足自己的需求，并提高用户体验。
- **个性化设置**：AI可以根据用户的个性化需求来设置相关的参数或配置。这种设置方式可以让网络设备更好地适应不同的场景和需求，并提高用户体验。

总之，AI技术可以大大简化人对网络设备的操控，并提高运维效率、用户体验和安全性等方面的表现。

## 应用场景/用例：

在工厂网络环境中，存在一台AGV小车因受到干扰，无线网络出现故障时，运维平台识别定位故障点位，运维人员通过AI排障快速定位故障根因，恢复生产效率。在密集办公或家居环境中，用户可以通过AI语音，手势等实现更加人性化的网络设备配置。

## 2.9 CSI数据压缩反馈

在WLAN中，CSI反馈是MIMO技术优化的关键。对单用户MIMO，CSI可帮助降低在使用线性接收机时，单个用户的多个空间数据流间的干扰。多用户MIMO，CSI可帮助降低用户间数据流的干扰。但传统压缩方法（如码本量化）面临高反馈开销和精度损失的权衡，尤其在大规模天线通信（如8x8 MIMO通信，联合波束成型通信）场景下效率低下。

## AI解决方案：

## • 基于传统机器学习算法的压缩反馈：

- 依托非监督式学习，利用聚类算法（如K-means算法）对协议提供的压缩结果进一步压缩。

## • 端到端压缩模型：

- 依托监督式学习，使用轻量化自动编码器（Autoencoder），在终端（STA）压缩CSI矩阵（如复数形式的H矩阵），在AP端解码还原。自动编码器（Autoencoder），可以自适应提取稀疏特征将高维CSI数据压缩成低维表示数据，然后在接收端重建，这样可以有效去除冗余信息获得更高的压缩率并降低重建误差。CSI数据可能具有特定的结构，比如空时频域的相关性，可以使用深度学习（如多维卷积神经网络、递归神经网络等）来有效捕捉这些复杂的非线性关系，对CSI进行精确建模和压缩，有效降低反馈开销并提升重建精度。

- 编码器：部署于STA，将高维CSI映射为低维隐向量。
- 解码器：部署于AP，通过多层神经网络层重建CSI。

## • 动态适应机制：

- 基于元学习（Meta-Learning），迁移学习（Transfer-Learning）训练模型，使其适应多场景（室内/室外、静态/移动），减少环境变化导致的性能波动。在不同的场景下（比如室内、室外、不同频段），CSI数据分布可能差异非常大。利用迁移学习技术，可以将在一个环境下学到的模型适应到另一个环境中，为CSI压缩提供一种高效的跨环境适配方案，提高压缩的有效性和灵活性。

## • 联合优化设计：

- 将CSI压缩与下游任务（如波束成型/联合波束成型、资源分配）联合训练，最大化系统吞吐量而非单纯追求重建误差最小化。

## 应用场景/用例：

在大规模MIMO场景下，通过AI压缩使CSI反馈量大幅降低同时保持波束成形增益误差在合理范围内。在高频段（6GHz/毫米波）实现信道快速追踪，通过CNN或时间卷积网络（TCN）压缩时变CSI实现毫秒级信道状态更新。

## 2.10 信道接入

WLAN网络中，站点（STA）使用的媒体访问控制（MAC）层基础接入方法是被称为分布式协调功能（DCF）的载波侦听多路访问/冲突避免（CSMA/CA）机制。

STA在发送数据前必须对无线媒介进行侦听。若检测到媒介在最小规定时长（如分布式帧间间隔DIFS）内持续空闲，STA将在等待一段额外的随机退避时长后获准发送帧。随机退避计数器的生成范围受竞争窗口（Contention Window）限制。初始范围被设置为从0到最小竞争窗口尺寸（CWmin）。若媒介被占用，竞争窗口将逐次加倍直至达到最大竞争窗口尺寸（CWmax），从而进一步降低冲突概率。

过去十余年间，无线局域网（WLAN）领域始终存在吞吐量持续提升与延迟严苛控制的必然发展趋势。要实现这些目标，高效的信道接入协议至关重要。相关分析表明，当前基于竞争的接入协议在密集部署场景中面临显著的性能劣化。

问题。二进制指数退避机制会引发短期不公平性，即连续传输失败会导致延迟性能进一步恶化。因此，需要更高效的信道接入方案来提升吞吐量，同时降低时延和抖动。

更进一步的，在高密度、多业务并发的 Wi-Fi 网络中，不同业务（XR/AR、4K 视频会议、工业物联、普通网页等）对时延、抖动和吞吐的要求差异极大，传统固定或静态调优的 EDCA 机制很难同时满足低时延保障、吞吐最大化和公平接入三重目标，常面临以下痛点：

- 业务拥塞：VO/VI 业务被 BE/BK 队列阻塞，导致画面卡顿、语音断续。
- 自适应性不足：用户数量或信道质量突变时，信道接入参数无法及时调整，引发性能震荡。
- 公平性缺失：个别流量过度占用空口，整体体验受损。

#### AI 解决方案：

##### 单设备：

- 高优先级业务感知与接入保护：

- 设备侧结合流量时序、QoS 标记，数据包大小等特征数据利用 XGBoost, DNN 网络, CNN 网络, LSTM+ 注意力机制等 AI 技术判别 XR、语音、AR、IoT、BE 等业务类别及其实时 QoS 需求。
- 设备侧根据 AI 识别结果将数据流映射进入对应队列。更进一步的，STA 侧还可依据 AI 建议决定是否开启 P-EDCA 竞争以获取更高优先级接入。

- 流量强度预测与智能调度映射

- 提取设备当前信道下一段时间的重要流量相关统计特征平均帧长、突发度等作为特征。利用特征提取结果利用 DNN 等轻量级深度神经网络预估短周期内各业务队列的负载强度，指导接入类别映射，空时资源分配。
- 站点侧设备利用 DNN 等轻量级神经网络等提供的流量预测结果动态选择主信道接入或非主信道接入以获得最佳业务体验。

##### 多设备：

- 多 AP 信道接入：

- 集中式信道接入决策：各 AP 上传流量，误包率，占空比等必要统计参数至边缘控制器，在边缘控制器利用遗传算法，模拟退火算法，DQN 算法等人工智能算法进行决策并下发全网最优信道接入策略配置，实现多 AP 之间的冲突避免和负载均衡。
- 将非主信道接入、OFDMA RU 动态分配，与 EDCA 参数动态配置等可用手段纳入决策集联合考虑，通过强化学习端到端构建指定目标（如容量最大，时延最低等）下的最优模型。

#### 应用场景/用例：

在高密度部署环境，AI 信道接入能够实时识别多样业务并动态调参，确保各项业务流畅。

## 第三章

# AI 与未来 WLAN 的空口协同

当前 IEEE 802.11 工作组成立了两个标准任务组，它们是 TGbn 和 TGbq，分别瞄准 Sub-7GHz 和毫米波频段的 WLAN。这两个项标准尽管仍在制定初期，但从标准任务组的提案中可一窥未来 WLAN 的雏形。未来的 WLAN 预计将包括多 AP 空口协同、毫米波波束管理等一系列新特性。这些先进特性涉及到更为复杂的多 AP 管理、波束管理，将优化和管理空间扩展到了新的维度，AI 对这些新维度的问题具有重要价值。

## 3.1 协同波束赋形（Coordinated Beam Forming）

协同波束赋形（Coordinated Beam Forming, CoBF）技术可以让多个接入点（Access Point, AP）协同工作，精确引导信号，减弱 AP 对空间重用并发中非目标终端（Station, STA）的影响，以提升总体网络性能。CoBF 技术的使用，主要包括两个步骤，CSI 获取以及根据 CSI 进行发送信号的调整与协作。

在 IEEE 802.11bn 中，仅支持两个 AP 进行 CoBF，示意图如下：

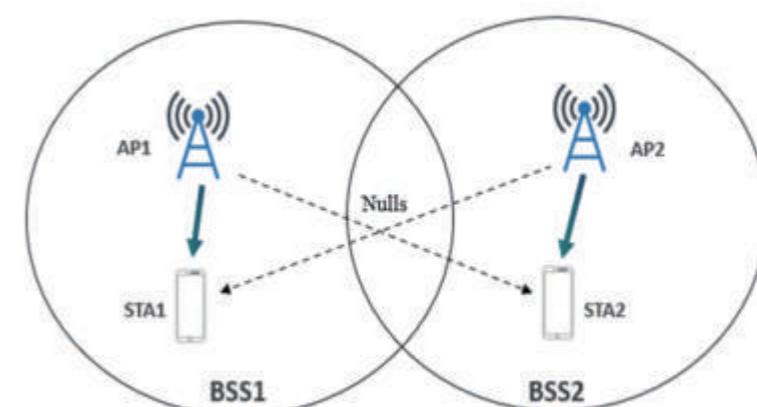


图 4 IEEE 802.11bn 中 CoBF 示意图

不同于 2.9 章中 AP 仅获取 BSS 内 STA 的 CSI，在 CoBF 机制中 AP 还需其他 BSS 内 STA 的 CSI。下图为 CoBF 中 CSI 获取的一个候选流程，称为基于顺序的 NDP 探测 (sequential NDP based sounding)。在该流程中，AP1 不仅获取关联 STA1 的 CSI，还获取了 AP2 关联的 STA2 的 CSI；AP2 同样获取了 STA1 和 STA2 的 CSI。

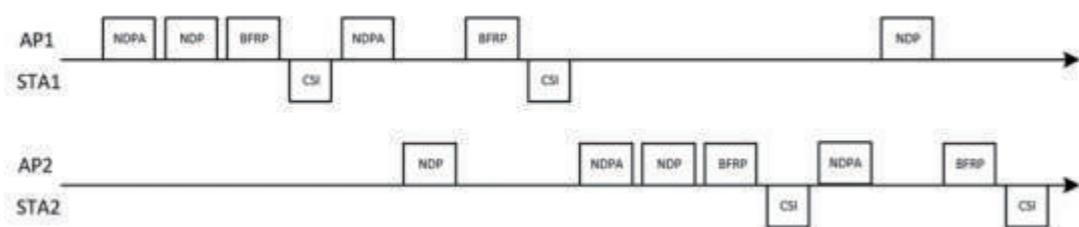


图 5 IEEE 802.11bn 中 CoBF 基于顺序的 NDP 探测

以 AP1 为例，在获取了 STA1 和 STA2 的 CSI 信息后，AP1 对 CSI 进行处理。继而在进行信号发送时，不仅可以针对 STA1 进行信号增强，同时可以减弱对 STA2 的干扰。这一过程对 AP1 和 AP2 的用户是互易的，从而双方都可以获得更大的信道容量。

从上面 CoBF 工作原理可以看出，CSI 对于 CoBF 中的波束赋形至关重要，因为它需要根据实时的信道状态来调整波束的方向和形状，以及利用 Nulling (即零陷或波束置零，指的是在特定方向上主动抑制信号，形成信号强度的零点，从而抑制干扰或噪声) 抑制或减弱 AP 对空间重用并发中非目标 STA 的影响。Nulling 的准确性直接决定 CoBF 的最终性能，而由信道变化引起的 CSI 变化会导致 Nulling 削弱，从而严重影响 CoBF 性能。可以借助 AI 预测信道变化，优化 CSI 反馈。

#### AI 解决方案：

- 利用 AI 技术可以对 CSI 进行压缩，有效减少反馈 CSI 所需的空口开销，详情见 2.9。
- 针对时变信道特性，采用循环神经网络 (Recurrent Neural Network, RNN) 预测未来 CSI 状态，提升系统的实时性和鲁棒性。例如，时域 CSI 预测通过历史信道数据进行高效建模，动态调整反馈频率，可以有效减少冗余信息传输并提高预测精度。
- 结合增量推理的在线学习和动态参数更新策略，实时动态更新模型参数，保持高精度的 CSI 预测以适应信道快速变化。例如，长短时记忆网络 (Long Short-Term Memory, LSTM) 模型在多模态输入 (如位置、图像、视觉、传感器数据等) 下逐步推断信道状态，实时调整波束方向。
- 利用生成对抗网络 (Generative Adversarial Networks, GAN) 生成高保真 CSI 特征，尤其在低比特量化场景下，能够生成与真实数据分布高度相似的样本，有效保留 CSI 的时空相关性及非线性特征，通过对抗训练增强数据可以有效提高预测鲁棒性和预测模型的泛化能力。
- 利用深度学习高效处理高维 CSI 数据，如利用卷积神经网络 (Convolutional Neural Networks, CNN) 和 Transformer 并结合终端位置，捕捉、提取并预测 CSI 的时间和空间特性，自适应的预测并生成最优预编码矩阵或参数。例如在根据 CSI 进行发送信号的调整时，可以借助 AI 对目标终端和其他终端的 CSI 进行自适应预测、整合与调整，使得发送的信号在目标终端处能够同相叠加，增强信号强度；同时，对于非目标区域和空闲终端，AP 会减少或停止发送信号，避免能量浪费和干扰。

#### 应用场景/用例：

在动态 (例如室内工厂或医院，存在移动障碍物导致信道突变) 与高密终端 (例如体育场馆、会议中心) 等需要多 AP 协同覆盖的场景，通过利用 AI 进行 CSI 预测可以提升预测精度与鲁棒性、降低计算与导频开销、适应复杂的环境并且有更好的实时性，能有效提升 CoBF 总体性能。

## 3.2 协同空间重用 (Coordinated Spatial Reuse)

802.11bn 引入协同空间复用 (Co-SR) 新特性，该技术的目标是通过协调控制多个 AP 的发射功率来实现并发传输，从而更高效地利用信道资源。Co-SR 传输由获得传输机会 (TXOP) 的 AP 发起，该 AP 成为分享 AP (Sharing AP)，被 sharing AP 选择进行协同并发传输的 AP 成为被分享 AP (Shared AP)。

Co-SR 技术的性能高度依赖高精度的干扰管理算法，涉及对 shared AP 的选择和功率调控，传统启发式方法在复杂拓扑和动态环境中效率较低，有时难以实现最优选择，可能引发互扰或资源浪费的问题。

#### AI 解决方案：

- 共享关系智能识别：**
  - 基于深度学习采集各 AP 及其关联 STA 的地理位置、路径损耗、历史干扰信息、信道状态信息等，有效挖掘具备并行传输能力的多组 APs 及其目的 STAs，将其分到一个共享组内。
  - 使用联邦学习在多个 AP 间共享干扰模型参数，可提升全局决策准确性。
- 功率控制优化：**
  - DRL 将功率控制建模为 MDP，状态空间为 AP-STA 间信号干扰水平、缓存大小、流量优先级、目标 STA、预估 SINR 等状态，动作空间为功率等级，智能体通过与环境交互优化功率设置，使得共享 AP 间干扰最小、总吞吐量最大。
  - 通过在线学习增量训练以适应新加入 AP 或动态场景，减少传统方法重新校准的开销。
- CoSR 调度优化**
  - 通过在线训练，可以有效降低功率、接收信号强度等测量数据的误差，从而在进行 CoSR 调度时，可以选取更准确的参数。
  - 通过对于重传次数、误包规律等多维信息的检测，可以有效辨别出由于随机退避碰撞、隐藏节点等原因造成的误包场景，避免由于此类非正常情况造成对 CoSR 调度的错误输入，提高调度参数准确性。

**应用场景/用例：**在多 AP 场景中，利用 AI 动态选择 shared AP 并优化功率，使系统容量提升，同时避免 VR 等实时业务因干扰导致的时延抖动。

## 3.3 TXOP 共享

802.11bn 引入了一种协同时分多址 (Co-TDMA) 新特性，该技术允许一个 AP (Sharing AP) 将其获得的 TXOP 中的一部分时间共享给另一个属于某一 AP 集合的 AP (Shared AP)，用于发送一个或多个 PPDU，以提升 shared AP 的接入机会。

在多 AP 密集部署的场景中，如何合理选择 shared AP 并确定时隙划分比例，涉及对网络负载、业务优先级和链路质量的全面感知与实时决策，传统方法易出现低效或不公平分配的问题。

#### AI 解决方案：

##### • 时隙动态分配：

- 使用 LSTM 模型对历史时隙利用率、业务到达速率等序列建模，结合注意力机制强化突发业务模式的捕捉能力，提前预测未来共享资源需求。
- 采用深度强化学习（DRL）：通过竞争 - 协作机制学习最优时隙请求策略，最大化整体网络效用函数，如加权吞吐量 + 公平性。

##### • QoS 感知调度：

- 采用分层强化学习，高层决策业务优先级（如视频 > 网页），底层微调时隙位置和长度，满足不同业务的时延敏感度。
- 采用离线预训练、在线部署的调度策略，通过离线阶段的大规模训练，模型能适应多种网络环境，在线阶段无需搜索与迭代，决策效率高。

**应用场景/用例：**在高并发IoT环境中，如智慧楼宇的早高峰时段，部分AP面临严重拥塞。引入AI优化的Co-TDMA机制后，系统可动态将空时资源分享给低负载、高优先级的shared AP，确保关键业务（如安全摄像头、语音通信）低延迟接入。

## 3.4 无缝漫游

在 802.11bn 中，引入了新的上下文共享机制，可使 STA 无需脱离关联状态 4，从而最小化漫游过程中的延迟和数据中断。尽管标准将提供基础机制框架，但在业界实际应用中，由于不同厂商、不同型号的 STA 在漫游过程中的行为存在诸多差异，固定的 AP 侧漫游引导策略在不同终端上的漫游引导效果参差不齐，无法有效保障漫游体验。

#### AI 解决方案：

##### • 用户画像：

- 网络画像：使用 DRL 深度强化学习（Q-Learning）学习不同网络的漫游策略。不同网络有不同的特点，使用固定引导策略不能最高效的引导终端漫游。使用 AI 模型将各种网络对应的有效漫游引导策略抽象为不同的网络漫游画像。例如通过 AI 模型学习得到特定网络拓扑下的漫游引导基线引导门限。
- 终端画像：使用神经网络算法（LSTM CNN 算法）学习不同终端的漫游策略，对不同漫游性能的终端提供不同的引导策略。使用 AI 模型学习分析终端行为抽象出不同的终端漫游画像，每个终端漫游画像对应于一套个性化漫游引导策略。
- 可基于 AI 绘制网络画像和终端画像，进行一终端一网络一画像，网端协同实现最佳漫游效果。

##### • 预测目标 AP：

- AP 或者 STA，都会在漫游候选 AP 列表中进行目标筛选，但是当组网中的 AP 较多，且相对 STA 有远有近时，每个候选 AP 的筛选价值是不同的。通过预测 STA 切换到每个 AP 的可能性，来提升候选效率，减少测量次数，以更快完成漫游决策。可采用 DNN 等深度神经网络，以 AP 间的信号强度、STA 的漫游历史切换关系、AP 的常态化负载等作为决策依据，预测 STA 漫游到各个 AP 上的可能性，使得 STA 的平均 MCS、RSSI 等为最大，漫游切换次数最小。

**效果：**在密集布网环境下，为 STA 的下一跳漫游，提供最优目标 AP 列表，以及最佳漫游门限，无需人工配置。使用漫游画像引导终端，减少终端漫游问题。

## 3.5 集成毫米波束管理和跟踪

AI 可赋能 11bq 集成毫米波系统的波束管理与高低频协同：毫米波（mmWave）通信依赖高增益窄波束实现高速传输，但波束管理面临波束搜索开销大、动态信道适配难、高低频协同效率低等问题。AI（深度学习、强化学习、联邦学习等）可显著优化波束管理流程，结合信道状态进行链路质量的智能预判与高低频链路协同。

#### 问题：

1. 传统波束搜索依赖穷举扫描（如 11ad SSW 波束扫描），导致初始接入和切换时延高，难以适应移动场景，并给高低频链路间的快速切换带来高开销困扰。
2. 低频（Sub-7GHz）覆盖广但容量低，毫米波波束增益大、干扰小、容量高但易中断，传统双连接切换策略静态，无法实时优化。
3. 毫米波波束窄（3°~15°），易受遮挡，传统固定波束宽度无法适应动态环境（如人流变化、车流影响）。

#### AI 解决方案：

##### 1. AI 辅助波束搜索触发预判

基于终端侧感知辅助的波束预测：对汽车终端可采用车载雷达，对手机可采用摄像头数据，获得 3D 雷达点云，进行环境感知、波束优化。对 WLAN AP 可数字孪生模拟部署局部区域的无线环境，AI 可预测未来 100ms 内的信道变化（如降雨衰减、遮挡物移动），提前调整波束参数。对 WLAN 移动 STA，利用运动传感器和 AI 轨迹预测，通过多模态融合模型（CNN+RNN）预判遮挡发生时间，提前调整波束。

##### 2. AI 驱动的波束范围预判（Beam Coverage Prediction）

基于历史数据的波束预选：利用 LSTM/Transformer 分析用户移动轨迹、信道历史状态（如 CSI、AoA/AoD），预测最优波束方向，减少扫描范围。基于估计得到的用户位置、速度，和学习到的环境特征（如建筑内墙体分布），可进行 Top-K 候选波束筛选，降低扫描时间。

AI 动态波束宽度调整：采用强化学习（RL），根据信道质量（如 SNR、RSSI）和用户分布，动态调整波束宽度（如广波束用于初始搜索，窄波束用于数据传输）。

##### 3. AI 建立跨频段的信道特性映射

利用低频信道信息（如 CSI）辅助毫米波波束训练，通过图神经网络（GNN）建模高低频信道间的空间相关性，减少毫米波波束搜索时间。

#### 应用场景/用例：

1. 体育场馆中，AI 基于实时人流热图调整波束覆盖，确保高密度用户区域无盲区。

2. 无人机 WLAN 毫米波通信中，AI 预判风力导致的姿态偏移，动态调整波束指向。

3. AI 使能的高低频协同波束管理，利用 Sub-6GHz 链路提供粗粒度波束指示，毫米波链路快速完成精对准。

## 3.6 Co-RTWT

协作 R-TWT (Co-RTWT) 使 AP 能够与 OBSS AP 协调其 R-TWT 调度，和 / 或将保护扩展到 OBSS AP 的 R-TWT 调度。Co-RTWT 需要协调多个 AP 的 R-TWT 调度来减少信道冲突，在复杂的环境中如何优化调度来提升多 AP 协同效率、降低时延、增强可靠性并节省功耗是一个亟待解决的问题。具体的，11bn 的 Co-RTWT 机制在高密度、高动态、多业务场景下面临以下技术挑战：

- **动态信道资源竞争**：多终端协同唤醒易引发信道争用，传统调度依赖人工规则，无法实时适配突发流量与多链路干扰。
- **超密集设备冲突抑制**：IoT 节点密度提升（如  $>1000$  节点 /  $m^2$ ）时，终端间隐含的拓扑关联性可能导致唤醒窗口重叠，显著增加冲突概率。
- **多链路能效与吞吐量权衡**：MLO 需跨频段同步调度唤醒时间，终端因频繁链路切换产生功耗波动，全局能效难以优化。
- **移动性场景下的服务质量保障**：移动终端轨迹的随机性导致网络拓扑快速变化，固定调度规则无法保障低时延、高可靠连接。

AI 解决方案：

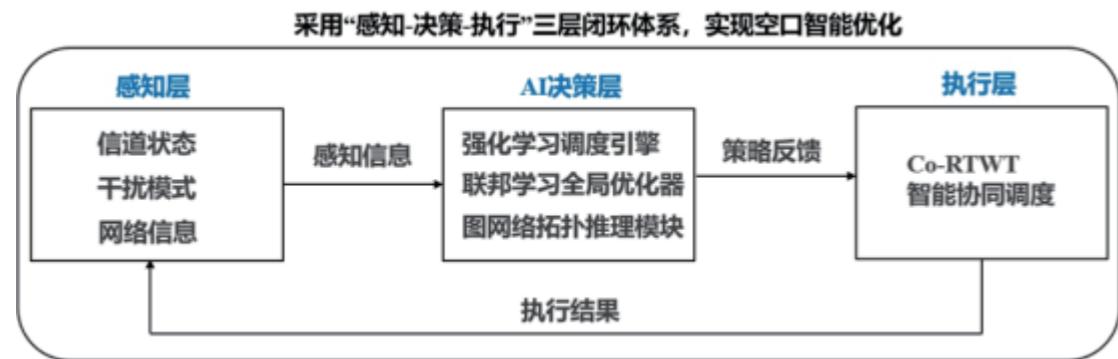


图 6 采用“感知-决策-执行”三层闭环体系，实现空口智能优化

#### • 强化学习驱动的协同唤醒

- 输入：多维度环境状态（信道负载矩阵、设备业务优先级标签、干扰频谱特征）。
- 模型：基于PPO（Proximal Policy Optimization）算法构建智能体，输出TWT窗口的时空分布策略，实现唤醒时间的非重叠分配。
- 优势：突破规则引擎的静态约束，动态规避突发流量导致的信道竞争。

#### • 联邦学习的全局能效管理

- 架构：基于横向联邦学习框架，AP与终端联合训练轻量化能效模型，终端上传加密梯度参数。
- 策略：在MLO场景下，为终端分配合适的唤醒频段优先级（如低功耗链路优先响应控制信令），均衡全局能耗。

#### • 图神经网络（GNN）的冲突预测

- 建模：将终端网络抽象为异构图（Heterogeneous Graph），节点属性包括终端位置、业务周期、历史冲突次数，边权重表征物理距离与干扰耦合强度。
- 推理：通过GAT（Graph Attention Network）模型识别高冲突风险终端群组，指导AP差异化分配Co-RTWT参数。

#### 应用场景/用例：

AI技术与Co-RTWT的深度融合，标志着无线网络从“规则驱动”向“智能内生”的范式变革。通过强化学习、图网络、联邦学习等技术，实现高密度场景下的动态资源优化、冲突概率压制与跨链路能效均衡，为工业4.0、元宇宙、智慧城市等场景奠定低功耗、高可靠的无线连接基石。

## 3.7 新信道接入机制

802.11bn 标准提供了新的信道接入机制，包括非主信道接入和高优先级 EDCA(P-EDCA) 接入：

**非主信道接入**：11bn 提供的非主信道接入（NP-CA）机制旨在解决主信道拥堵时次要信道的利用率低的问题。该技术旨在提高吞吐量和降低接入延迟，通过动态使用非主信道来优化频谱利用。

工作机制包括：当主信道忙时，设备切换到空闲的非主信道继续后退和传输；当主信道空闲时，设备切换回主信道。

**P-EDCA 接入**：11bn 提供的优先级 EDCA（P-EDCA）是 EDCA 机制的增强版本，旨在减少低延迟 AC\_VO 流量（其他用例待定）的接入延迟分布尾部。使用 P-EDCA 的超高可靠性（UHR）站点（STA）会通过特定规则，平衡对未使用 P-EDCA 的站点的影响。

工作机制包括：当站点存在高优先级业务时，可依托 P-EDCA 机制以更短的仲裁间隔发送延迟信号（Defer Signal）开启 P-EDCA 竞争从而更优先的获取无线信道使用权。

AI 解决方案：

- **信道接入决策**：
  - 利用深度强化学习（DRL）包括 DQN，以及由 DQN 衍生出的 DDPG 等算法获取最优信道接入参数组合；奖励函数综合“关键业务时延、总吞吐、公平指数”，保证不同业务同时获益。
  - 强化学习调优过程中引入自监督策略平滑，通过自适应阈值，避免频繁跳变造成的空口震荡。

# 第四章

## 挑战与未来方向

### 4.1 来自算力、兼容性和泛化性方面的挑战

#### 4.1.1 边缘 AI 的算力限制

近年来，随着人工智能（AI）技术的持续发展，越来越多的 WLAN 性能优化功能可通过 AI 算法辅助实现，这也使得边缘侧，特别是无线路由器，对本地算力资源的需求日益迫切。传统嵌入式处理器在单精度浮点运算能力、内存带宽以及并行计算效率方面普遍受限，难以支撑复杂模型在实际场景中的实时运行需求。为有效突破算力瓶颈，推动边缘智能在 WLAN 场景中的广泛落地，亟需从计算架构设计、模型优化策略与软硬件协同机制等多个层面开展系统性优化。

- 模型压缩：针对边缘设备资源受限的特点，系统在模型设计与部署阶段全面引入 AI 模型压缩技术，以降低模型的存储开销与推理计算负载。主要手段包括：低比特量化与极低比特量化（比 1-bit 权重网络），在尽量保持精度的前提下显著压缩模型体积；知识蒸馏，通过迁移知识，以构建更小、更高效的推理模型；稀疏化与剪枝机制，用于进一步减少冗余计算路径与参数存储需求。通过上述压缩策略，将模型缩小后，将有可能在边缘设备，特别是路由器设备上可以进行部署，实现显著降低单次推理的平均耗时与功耗，提升整体系统的运行效率与可部署性的功能。
- 端云协同：为兼顾推理性能、系统能效与服务弹性，系统构建了基于分层智能架构的端云协同机制。该机制将低延迟、高频次的核心任务优先在本地执行，而将算力密集型或跨域融合类复杂任务迁移至云端处理，形成本地快速响应 + 云端深度计算的多级算力协同模式。
- 全网优化：在 AI 与 WLAN 深度融合的智能化演进过程中，AI 算力的应用已不再局限于单点设备的本地推理，而是逐步向全网协同的分布式智能推理能力拓展。通过在多个无线路由器及终端节点上部署具备感知与推理能力的轻量化算力单元，系统能够实现对网络运行状态的连续感知与基于数据驱动的动态决策。依托分布式 AI 模型对 WLAN 网络中流量分布、用户接入行为、干扰特征等多维数据的实时分析，系统可在控制面动态优化信道分配、发射功率控制、用户关联引导等关键参数，实现对资源的智能化编排与按需调度。在频谱资源受限、接入密度不断上升的现实条件下，此类智能机制显著提升了网络整体的接入效率、服务质量与环境适应能力，推动 WLAN 网络向自优化、自适应的智能体系架构演进。

在实际部署中，系统可基于设备算力状态、功耗阈值、网络带宽与延迟等实时指标，动态评估各类任务的资源需求，并进行智能调度与卸载决策。通过这种协同方式，系统在保障服务质量的同时，实现推理任务的最优分配与整体能效比的持续提升。

AI 技术与传统的无线算法相比，对数据和算力提出了更高的要求，因此设计部署架构时应充分考虑其带来的通讯、计算、存储开销。目前，WLAN 的设备主要分为 AP、Controller 和云端服务器。AP 是负责射频收发的边缘设备，如 CSI 等空口数据由 AP 直接获取，底层算法部署在 AP 上可以节省网络中的通讯开销，然而 AP 成本敏感，普遍性能较弱，不适合部署较大的模型。Controller 是 WLAN 的信息和控制中心，跨 AP 的集中式（centralized）优化算法部署在 Controller 上最为高效。云端服务器目前收集网络信息，提供与用户交互的高级功能，计算和存储能力强且可弹性拓展，但通讯成本高、时延不可控，适合部署 AI 助手等数据依赖弱的算法。随着 AI 技术深入 WLAN，算法的部署将越来越精细，对一个功能中的数据流或模型分级拆分，分别由 AP、Controller 和云端处理自己擅长的部分或许是未来的发展方向。

#### 4.1.2 支持 AI 的新设备与不支持 AI 的老设备间的兼容

- WLAN 无线网络正逐步引入基于人工智能的智能调节机制，以实现更高效的频谱管理、干扰规避、网络负载均衡与服务质量保障。该类功能通常依赖于具备本地推理能力的 AI 增强型 WLAN 路由设备，并可能对现行 WLAN 协议栈（如 802.11 系列）进行扩展或增强，从而在控制面和数据面引入智能决策能力。在此背景下，设备层面出现了明显的能力分化：传统 WLAN 终端设备由于缺乏 AI 协同接口和算力支撑，无法直接参与 AI 推理或策略协同；而新型 AI 感知终端可与 AI 路由器进行更深层次的状态互通与协同优化。由此产生的协议兼容性与性能异构性问题成为 AI 在 WLAN 场景中落地的关键技术挑战之一。
- 尽管如此，AI 增强型 WLAN 路由器在系统层面可通过感知与调控机制，间接优化传统设备的网络性能表现。例如，通过对全网流量状态的实时学习与动态调度，AI 路由器可为传统终端提供更优的接入信道、更平稳的带宽保障与更少的干扰，进而在不改变终端硬件的前提下实现被动式性能提升。
- 相比之下，新型 AI 感知终端设备（支持 AI 信令协同或具备本地协同机制）在与 AI 路由器协作运行时，可实现更高粒度的网络状态协同与资源分配，进一步提升连接稳定性、负载均衡效率与 QoS 保障能力，获得显著优于传统设备的性能提升空间。
- 综上所述，AI 功能的引入虽然对协议与设备提出了演进要求，但在保持对传统设备兼容性的同时，亦可通过智能调度机制实现网络整体性能的提升，并为新型设备释放更大潜能，推动 WLAN 网络架构迈向更加智能、自适应与高效的演进方向。

#### 4.1.3 复杂场景下的感知能力泛化

从 2.6 节中，可见 AI WLAN 感知技术已经取得了大量研究成果。然而，由于应用场景的多样性以及 WLAN 设备部署环境的复杂性，当前的 WLAN 感知算法大多为专用定制方案。为了满足实际需求，WLAN 设备往往需要集成十余种感知算法，带来显著的开发和运维负担。针对这一问题，我们将目光投向大模型技术，希望借助其统一建模和泛化能力，简化算法设计与系统集成过程。

回顾自然语言处理的发展历程，其早期同样存在多种技术路线和分散应用。而大模型的兴起打破了这一局面，通过统一架构和大规模预训练，将复杂的算法设计问题转化为算力驱动的问题，大幅提升了技术水平。当前，AI WLAN感知的数据基础正在逐步完善，未来有望基于大模型方法构建通用的WLAN感知预训练模型。WLAN感知也有潜力成为大模型多模态能力的重要组成部分，进一步推动WLAN感知技术发展，并加速通感一体化产业的落地与爆发。

## 4.2 未来发展趋势

短期能力：智能化能力优于当前普通用户参数配置和优化，用户可一键配置极简操作实现优化。802.11be系统的空口可与AI深度结合，实现亚毫秒级调度和业务保障。

中期能力：智能化能力优于专家级参数配置和优化，长期守点观察，加分时段、分业务针对性调优和故障处理，随WLAN技术向IEEE 802.11bn/bq新空口演进，服务于新空口特性能力。未来WLAN迈向毫米波，AI对WLAN 802.11bq中的毫米波束管理、高低频链路管理都将发挥巨大价值。

远期能力：网络设备间自适应分享智能经验，联合学习和优化，故障预判和防患于未燃，对协议自定义部分进行AI自定义协商，智能体设备间生成针对本地场景的最优协议行为和规则，例如信道竞争规则、碰撞化解规则等。AI化频谱共享可实现WLAN内及WLAN与其他无线系统间高效的频谱协调及传输协同。

# 结论

新工业革命对网络接入技术提出了诸多新需求，如数据处理量剧增、对实时性与可靠性要求严苛、支持海量终端接入以及多种接入技术协作等。这其中以 WiFi、星闪、蓝牙、Zigbee 等为代表的 WLAN 在其中起到了关键作用，如 WiFi 承担了 70% 的接入流量、31% 的 IoT 连接，蓝牙也承担了 29% 的 IoT 连接，所以提升 WLAN 的带宽、实时性、可靠性、并发终端数等指标对新工业革命有重要意义。

AI 使 WLAN 从“被动响应”迈向“主动优化”，解决传统算法不能满足无线环境、无线业务的复杂多变的问题，显著提升可靠性、效率与用户体验，满足新质生产力对带宽、延迟、稳定性的要求，成为新工业革命的关键数据通路。AI 技术在通信网络上应用的逐步深化将使传统的网元由功能单元向网络智能体转变，通过网络智能体之间的协作，将把传统的通信网络转变成智能网络。

本研究报告总结了当前 AI 应用在 WLAN 网络上的技术方向，这些技术方向将会随着时间的推移迭代更新。对于这些技术方向，建议通过技术标准、测试认证等方式逐步落地，切实推动产业的数字化转型和新工业革命的发展。

# 缩略语表

缩略语	英文全称	中文
AGV	Automated Guided Vehicle	自动导引车
ARIMA	Autoregressive Integrated Moving Average Model	自回归整合移动平均模型
Co-SR	Coordinated Spatial Reuse	协同空间复用
Co-BF	Coordinated Beamforming	协同波束赋形
Co-RTWT	Cooperative Restricted Target Wake - up Time	协作的受限目标唤醒时间
Co-TDMA	Coordinated Time - Division Multiple Access	协同时分多址
CSI	Channel State Information	信道状态信息
CSMA	Carrier Sense Multiple Access	载波侦听多路访问
DCF	Distributed Coordination Function	分布式协调功能
DNN	Deep Neural Network	深度神经网络
DRL	Deep Reinforcement Learning	深度强化学习
DQN	Deep Q - Network	深度 Q - 网络
DARA	Data - Driven Rate Adaptation algorithm	数据驱动的速率自适应算法
DDPG	Deep Deterministic Policy Gradient	深度确定性梯度
EDCA	Enhanced Distributed Channel Access	增强的分布式信道访问
FTTR	Fiber to the Room	光纤到房间
GAN	Generative Adversarial Network	生成对抗网络
GAT	Graph Attention Network	图注意力网络
GNN	Graph Neural Network	图神经网络
IoT	Internet of Things	物联网

缩略语	英文全称	中文
KNN	K - Nearest Neighbor algorithm	k近邻（算法）
LLM	Large Language Model	大语言模型
LSTM	Long Short - Term Memory	长短时记忆
MIMO	Multiple - Input Multiple - Output	多输入多输出
MDP	Markov Decision Process	马尔可夫决策过程
MLO	Multi - Link Operation	多链路运行
MCS	Modulation and Coding Scheme	调制与编码策略
OLT	Optical Line Terminal	光线路终端
ONU	Optical Network Unit	光网络单元
PON	Passive Optical Network	无源光网络
PPO	Proximal Policy Optimization	近似策略优化
P-EDCA	Priority - Enhanced Distributed Channel Access	具有优先级的增强分布式信道访问
QoS	Quality of Service	服务质量
RNN	Recurrent Neural Network	循环神经网络
RRM	Radio Resource Management	无线资源管理
RSSI	Received Signal Strength Indicator	接收信号强度
SNR	Signal - to - Noise Ratio	信噪比
SVM	Support Vector Machine	支持向量机
TCN	Temporal Convolutional Network	时间卷积网络
TWT	Target Wake - up Time	目标唤醒时间
UHR	Ultra - High Reliability	超高可靠性
XGBoost	Extreme Gradient Boosting	极端梯度提升

# 参考文献

[1] Lazaridou, Angeliki, and Marco Baroni. "Emergent multi-agent communication in the deep learning era." arXiv preprint arXiv:2006.02419 (2020).

[2] Zou, Hang, Qiyang Zhao, Lina Bariah, Mehdi Bennis, and Merouane Debbah. "Wireless multi-agent generative AI: From connected intelligence to collective intelligence." arXiv preprint arXiv:2307.02757 (2023).

[3] ZS. Ji, Q. Wang, S. Wu, J. Tian, X. Li and W. Wang, "Deep learning based user grouping for FD-MIMO systems exploiting statistical channel state information," in China Communications, vol. 18, no. 7, pp. 183-196, July 2021.

[4] W. Zhou, T. Zhu, D. Ye, W. Ren and K. -K. R. Choo, "A Concurrent Federated Reinforcement Learning for IoT Resources Allocation With Local Differential Privacy," in IEEE Internet of Things Journal, vol. 11, no. 4, pp. 6537-6550, 15 Feb.15, 2024.

[5] H. Xiang, J. Peng, Z. Gao, L. Li and Y. Yang, "Multi-Agent Power and Resource Allocation for D2D Communications: A Deep Reinforcement Learning Approach," 2022 IEEE 96th Vehicular Technology Conference (VTC2022-Fall), London, United Kingdom, 2022, pp. 1-5.

[6] F. Lu, F. Yuan, Y. Li, X. Song, C. Liu and F. Liu, "5G VoNR Traffic Real-time Prediction Method based on LSTM," 2023 5th International Conference on Frontiers Technology of Information and Computer (ICFTIC), Qiangdao, China, 2023, pp. 915-919.

[7] Q. Cui, Z. Zhang, Y. Shi, W. Ni, M. Zeng and M. Zhou, "Dynamic Multichannel Access Based on Deep Reinforcement Learning in Distributed Wireless Networks," in IEEE Systems Journal, vol. 16, no. 4, pp. 5831-5834, Dec. 2022.

[8] R. Huang, M. Guo, C. Gu, S. He, J. Chen and M. Sun, "Toward Scalable and Efficient Hierarchical Deep Reinforcement Learning for 5G RAN Slicing," in IEEE Transactions on Green Communications and Networking, vol. 7, no. 4, pp. 2153-2162, Dec. 2023.

[9] [https://www.ieee802.org/11/Reports/tgbn\\_update.htm](https://www.ieee802.org/11/Reports/tgbn_update.htm)

[10] [https://www.ieee802.org/11/Reports/tgbn\\_update.htm](https://www.ieee802.org/11/Reports/tgbn_update.htm)

[11] Xia, Dong, Jonathan Hart, and Qiang Fu. "Evaluation of the Minstrel rate adaptation algorithm in IEEE 802.11 g WLANs." In 2013 IEEE International Conference on Communications (ICC), pp. 2223-2228. IEEE, 2013.

[12] Sammour, Ibrahim, and Gerard Chalhoub. "Evaluation of rate adaptation algorithms in IEEE 802.11 networks." Electronics 9, no. 9 (2020): 1436.

[13] Mortaheb, Matin, Mohammad A. Amir Khojastepour, Srimat T. Chakradhar, and Sennur Ulukus. "Deep Learning-Based Real-Time Rate Control for Live Streaming on Wireless Networks." In 2024 IEEE International Conference on Machine Learning for Communication and Networking (ICMLCN), pp. 263-267. IEEE, 2024.

[14] Queirós, Rúben, Eduardo Nuno Almeida, Helder Fontes, José Ruela, and Rui Campos. "WLAN rate adaptation using a simple deep reinforcement learning approach." In 2022 IEEE Symposium on Computers and Communications (ISCC), pp. 1-3. IEEE, 2022.

[15] F. Qi, J. Guo, Y. Cui, X. Li, C. Wen and S. Jin, "Deep Learning-Based CSI Feedback in WLAN Systems," 2024 5th International Symposium on Computer Engineering and Intelligent Communications (ISCEIC), Wuhan, China, 2024, pp. 43-48, doi: 10.1109/ISCEIC63613.2024.10810137.

[16] 802.11-23/0275r2, Improved AIML Enabled Index Based Beamforming CSI Feedback Schemes

[17] 802.11-23/0290r2, Study on AI CSI Compression

[18] S. Szott, K. Kosek-Szott, P. Gawłocz, J. T. Gómez, B. Bellalta, A. Zubow, F. Dressler, "WLANMeets ML: A Survey on Improving IEEE 802.11 Performance with Machine Learning," IEEE Communication Surveys & Tutorials, Vol.24, Issue 3, Juen 2022

[19] Z. Guo, Z. Chen, P. Liu, J. Luo, X. Yang and X. Sun, "Multi-agent reinforcement learning-based distributed channel access for next generation wireless networks", IEEE Journal on Selected Areas in Communications, Vol. 40, Issue 5, May 2022

[20] Y. Ding, S. Liew and T. Wang, "Non-Uniform Time-Step Deep Q-Network for Carrier-Sense Multiple Access in Heterogeneous Wireless Networks", IEEE Transactions on Mobile Computing, Vol. 20, Issue 9, Sept 2021

[21] Ali Z A, Abduljabbar Z H, Tahir H A, et al. eXtreme gradient boosting algorithm with machine learning: A review [J]. Academic Journal of Nawroz University, 2023, 12(2): 320-334.

