

## 基于深度扩散确定性策略梯度的 Wi-Fi 网络性能优化

刘铁, 方旭明, 何蓉

(西南交通大学信息科学与技术学院, 四川 成都 611756)

**摘要:** Wi-Fi 网络性能优化通常是多参数、多目标动态优化问题, 在数学建模上面临巨大挑战。深度强化学习 (DRL, deep reinforcement learning) 不需要复杂的数学建模, 近年来被广泛应用于 Wi-Fi 网络性能优化。同时, 生成扩散模型 (GDMs, generative diffusion models) 在多个领域中对复杂数据分布的建模取得了显著进展。因此, 将 DRL 与 GDMs 相结合可以增强其对 Wi-Fi 网络性能优化的能力。Wi-Fi 网络的典型介质访问控制 (MAC, medium access control) 接入机制是分布式协调功能 (DCF, distributed coordination function), 在竞争终端数量较多时, 其性能会显著下降。提出了一种深度扩散确定性策略梯度 (D3PG, deep diffusion deterministic policy gradient) 算法, 将扩散模型与深度确定性策略梯度 (DDPG, deep deterministic policy gradient) 框架相结合, 以优化 Wi-Fi 网络性能。此外, 还提出了一种基于 D3PG 算法的接入机制, 联合调整竞争窗口和聚合帧长度。仿真实验表明, 该机制在密集 Wi-Fi 场景中显著优于现有 Wi-Fi 标准的 MAC 接入机制, 在竞争用户数量急剧增加时, 仍能保持吞吐量性能稳定。

**关键词:** Wi-Fi 网络; 生成扩散模型; 深度强化学习; 性能优化; 接入控制

**中图分类号:** TN929.5

**文献标志码:** A

**doi:** 10.11959/j.issn.2096-3750.2025.00494

## Deep diffusion deterministic policy gradient based performance optimization for Wi-Fi network

LIU Tie, FANG Xuming, HE Rong

School of Information Science and Technology, Southwest Jiaotong University, Chengdu 611756, China

**Abstract:** The optimization of Wi-Fi network performance typically constitutes a multi-parameter, multi-objective dynamic optimization problem, which presents significant challenges in mathematical modeling. Deep reinforcement learning (DRL), which obviates the need for complex mathematical formulations, has been widely applied in recent years to optimize Wi-Fi network performance. Meanwhile, generative diffusion models (GDMs) have achieved remarkable progress in modeling complex data distributions across various domains. Therefore, integrating DRL with GDMs can further enhance its capabilities in optimizing Wi-Fi network performance. The typical medium access control (MAC) mechanism in Wi-Fi network is the distributed coordination function (DCF), whose performance significantly degrades as the number of contending terminals increases. A deep diffusion deterministic policy gradient (D3PG) algorithm was proposed, which integrated diffusion models with the deep deterministic policy gradient (DDPG) framework to optimize Wi-Fi network performance. In addition, an access mechanism that jointly adjusted the contention window and the aggregation frame length based on the D3PG algorithm was proposed. Simulations have demonstrated that this mechanism significantly outperforms existing Wi-Fi standards in dense Wi-Fi scenarios, maintaining throughput performance even as the number of

收稿日期: 2025-02-19; 修回日期: 2025-06-10

通信作者: 方旭明, xmfang@swjtu.edu.cn

基金项目: 国家自然科学基金资助项目 (No. 62071393); 四川省重点研发计划项目 (No. 2024YFHZ0093)

**Foundation Items:** The National Natural Science Foundation of China (No. 62071393), Sichuan Science and Technology Program (No. 2024YFHZ0093)

users increases sharply.

**Key words:** Wi-Fi network, generative diffusion model, deep reinforcement learning, performance optimization, access control

## 0 引言

随着 Wi-Fi 技术的不断发展, 8K 视频流、增强/虚拟现实<sup>[1-2]</sup> (AR/VR, augmented/virtual reality) 以及远程医疗等先进网络应用快速兴起, 这些应用对网络性能提出了前所未有的挑战。这些需求已显著超越现有通信标准的能力范围, 推动了下一代 Wi-Fi 技术<sup>[3]</sup> (尤其是 IEEE 802.11be, 即 Wi-Fi 7) 的发展。这些新技术旨在提供极高的吞吐量和更低的时延, 以满足未来复杂应用的需求。

然而, Wi-Fi 网络介质访问控制 (MAC, medium access control) 层的参数众多, 且部分参数相互之间存在一定的关联性和制约性。在优化网络性能过程中, 传统数学建模方法在处理无线信道的随机性、多变性以及参数间复杂的相互依赖性时面临诸多困难<sup>[4-6]</sup>。例如, 竞争窗口 (CW, contention window) 和聚合帧长度这两个参数存在一定的耦合性。较长的聚合帧长度可以减少传输开销, 也可能导致更高的重传开销和更高的数据包错误率, 尤其是在密集部署的 Wi-Fi 场景中, 但是这一问题可以通过增大竞争窗口或减小聚合帧长度来缓解。近年来, 机器学习 (尤其是强化学习) 算法的进展为这一问题提供了有效的解决方案, 其自适应学习能力和数据处理能力能够避免复杂的数学建模, 因此在优化 Wi-Fi 网络以满足不断变化的需求中发挥着越来越重要的作用<sup>[7-9]</sup>。

近几年, 生成式人工智能 (GAI, generative artificial intelligence) 在多个领域取得了显著进展<sup>[10-13]</sup>。GAI 技术擅长通过分析包含文本、图像和声音在内的各种数据集来生成新内容<sup>[14]</sup>。特别是在数据增强领域<sup>[15]</sup>, 生成模型能够合成额外数据以增强机器学习模型, 在数据稀疏或隐私保护要求较高的场景中提供关键支持。对于网络优化任务 (如联合优化相互耦合的参数), GAI 在处理高度复杂的数据分布和捕捉复杂关系方面表现出色。但是, 如何为不同环境确定超参数调整的最佳组合也是一项挑战。

Du 等<sup>[16]</sup>介绍了生成扩散模型 (GDMs, generative diffusion models) 在网络优化问题中的应用,

并通过功率优化示例展示了其在总速率方面相较于传统深度强化学习方法的优越性能。另一项研究<sup>[17]</sup>针对下一代互联网高效内容生成能力的需求, 提出了结合深度强化学习和扩散模型的 AI 生成优化决策 (AGOD, artificial intelligence generative optimal decision) 算法, 将生成扩散理论应用于网络性能优化。

在 Wi-Fi 网络中, 分布式协调功能 (DCF, distributed coordination function) 是 Wi-Fi 标准的核心 MAC 接入机制<sup>[18-19]</sup>, 其基于载波侦听多路访问/冲突避免 (CSMA/CA, carrier sense multiple access with collision avoidance) 和二进制指数退避 (BEB, binary exponential backoff) 原则运行。DCF 遵循“先听后说”原则, 即设备在传输前会检测信道是否空闲。如果信道繁忙, 设备会在  $[0, CW_{\max}]$  范围内随机退避, 每次冲突后竞争窗口会加倍。若信道在分布式帧间间隔 (DIFS, distributed interframe space) 时间内一直保持空闲或退避计数器减到 0, 设备便可以接入信道传输数据。尽管 BEB 在低密度场景中表现良好, 但随着站点 (STA, station) 数量的增加, 其性能会显著下降<sup>[20-21]</sup>。Bianchi 等<sup>[22]</sup>的研究表明, 密集的竞争节点会导致更高的冲突概率、数据包丢失率和吞吐量下降。这一局限性对高密度基本服务集 (BSS, basic service set) 环境提出了重大挑战。

帧聚合是一种用于提升 Wi-Fi 网络 MAC 性能的有效技术, 聚合帧长度会影响时延、信道利用率、吞吐量等<sup>[23-24]</sup>。因此, 有必要研究如何在不同信道条件和不同服务质量 (QoS, quality of service) 需求下优化聚合帧长度。Camps-Mur 等<sup>[25]</sup>讨论了如何利用帧聚合机制来提升 Wi-Fi 网络的 QoS。Coronado 等<sup>[26]</sup>提出了一种基于机器学习的自适应方法, 通过考虑信道条件优化帧大小选择, 其平均吞吐量比标准聚合机制提高了 18.36%。Zhou 等<sup>[27]</sup>提出了一种基于双深度 Q 学习 (DDQN, double deep Q-network) 的联合帧长度与速率自适应 (JFRA, joint frame length and rate adaptation) 方案, 其性能分别比 Minstrel HT 算法和 Thompson 采样算法高出 21.3% 和 68.9%。

基于以上分析，本文提出一种联合调整竞争窗口和聚合帧长度的方法，以提升终端密集分布的Wi-Fi网络吞吐量。由于很难获得用户的最佳竞争窗口大小和聚合帧长度之间精确的数学关系，需要能够建模其数学关系的模型或算法来同时调整这两个参数。本文提出了一种结合GDM和深度确定性策略梯度框架<sup>[28]</sup>（DDPG）的算法，即深度扩散确定性策略梯度（D3PG, deep diffusion deterministic policy gradient）算法，其融合了DDPG强化学习的优势与GDM的复杂建模能力，为Wi-Fi网络性能优化提供了新的解决方案。

### 1 系统模型

系统模型如图1所示，其中包括一个接入点（AP, access point）和 $N_s$ 个随机分布在以AP为中

心、半径为 $r$ 的圆形区域内的STA。D3PG算法代理部署于AP处，负责收集训练模型所需的所有数据，这些数据可以直接从AP处获取或通过AP与STA的交互中获得。本文目标是训练模型以优化密集Wi-Fi场景中的总吞吐量。

DDPG算法与D3PG算法的区别主要在于策略网络（Actor）的建模方式，但优化过程同样可以视为一个马尔可夫决策过程（MDP, Markov decision process)<sup>[29]</sup>，要求模型的代理收集状态、动作和奖励信息。在训练过程中，位于AP的代理收集状态信息为 $s_t$ ， $s_t = \{ ITP, PLR_{t,i} | i \in N_s \}$ 由信道空闲时间比例（ITP, idle time proportion）和数据包丢失率（PLR, packet loss rate）组成，下标 $t$ 和 $i$ 分别表示仿真时刻和STA编号。ITP表示AP在特定时间段 $T$ 内检测到信道空闲的时间比例，其计算式如下




图1 系统模型

$$\text{ITP}_t = \frac{T_{\text{idle}}}{T} \quad (1)$$

PLR可以代表数据传输的可靠性,通过特定时间段内传输的帧数 $n_{\text{TX},i}$ 和接收到的确认帧(ACK)数 $n_{\text{ACK},i}$ 计算得出

$$\text{PLR}_{t,i} = 1 - \frac{n_{\text{ACK},i}}{n_{\text{TX},i}} \quad (2)$$

其中, $n_{\text{TX},i}$ 和 $n_{\text{ACK},i}$ 分别表示第*i*个STA传输的帧数量和接收到的ACK帧数量。

随后,D3PG算法代理从获取的状态 $s_t$ 出发,通过条件扩散模型以及随机生成的与动作空间大小匹配的噪声进行处理,以获取最优动作。经过多次去噪步骤后,模型输出一个动作 $a_t = \{CW_{t,i}, L_{t,i} | i \in N_s\}$ ,其中包含每个STA的竞争窗口 $CW_{t,i}$ 和聚合帧长度 $L_{t,i}$ 。代理模型直接输出0到1之间的连续数值,将 $CW_{t,i}$ 离散映射为 $CW_{\min}$ 和 $CW_{\max}$ 之间的整数值,同时将 $L_{t,i}$ 离散映射为 $L_{\min}$ 和 $L_{\max}$ 之间的整数值。AP随后将动作下发至各个STA,并在Wi-Fi网络中执行一段时间,从而产生奖励 $r_t$ 和下一个状态 $s_{t+1}$ 。这样就完成了一条轨迹 $\tau = (s_t, a_t, r_t, s_{t+1})$ ,并将其存储在经验池 $D$ 中以供后续模型优化使用。

奖励函数的设计基于吞吐量的提升来优化这些调整

$$r_t = 2 \times (\text{sigmoid} \frac{\text{Thr}_t}{\lambda} - 0.5) \quad (3)$$

其中, $\text{Thr}_t$ 表示*t*时刻整个系统的总吞吐量, $\lambda$ 是一个超参数,用于控制奖励对吞吐量的敏感度。考虑实用性, $\lambda$ 可以设置为期望的总吞吐量或最大香农容量。这使得能够将表示吞吐量的任何正实数归一化到[0,1],从而准确反映奖励信息并促进模型收敛。

通过这种方法,AP处的D3PG算法代理能够学习复杂网络环境中的最优策略,从而在Wi-Fi密集场景中提升整体网络性能。

## 2 基于扩散模型的优化原理

D3PG算法基于深度确定性策略梯度算法,其区别主要在于使用条件扩散模型替代了决策网络,下面先介绍扩散模型的原理。生成扩散模型可分为两部分:前向扩散过程和反向扩散过程<sup>[30]</sup>。

### 2.1 前向扩散过程

在计算机视觉领域, $x_t$ 表示图像,而在Wi-Fi网络优化场景中, $x_t$ 表示一个优化解,即在时间*t*时为每个STA设置的竞争窗口CW或聚合帧长度。

式(4)展示了噪声如何在优化解中扩散

$$x_{t+1} = \sqrt{\beta} \times \varepsilon + \sqrt{1 - \beta} \times x_t \quad (4)$$

其中, $\varepsilon$ 是与 $x_t$ 维度相同的高斯噪声, $\beta$ 是噪声扩散系数,它是一个0到1之间的标量。 $x_{t+1}$ 是 $x_t$ 加上噪声后的结果。在扩散过程中, $\beta$ 值从接近0开始逐渐增加到接近1,这一过程表示噪声逐渐扩散到原始数据中, $\beta$ 逐渐增大表明扩散速度在加快。

扩散模型的前向过程就是从 $x_0$ 得到 $x_t$ 的过程,通过式(4),经过一步一步前向扩散的推导,得到式(5)

$$x_t = \sqrt{1 - \bar{\alpha}} \times \varepsilon + \sqrt{\bar{\alpha}} \times x_0 \quad (5)$$

其中, $x_0$ 是最优解, $\bar{\alpha} = \alpha_t \alpha_{t-1} \cdots \alpha_1$ ,且 $\alpha_t = 1 - \beta_t$ ,这样定义 $\alpha_t$ 是为了简化推导结果的表达。于是得到了 $x_0$ 与 $x_t$ 之间的关系式。至此,GDM的前向扩散过程就推导完成了。

### 2.2 反向扩散过程

反向扩散过程涉及从已知的 $x_t$ 推导回 $x_0$ 的关系。类似于前向扩散过程,首先推导反向扩散一步的关系式,即 $P(x_{t-1}|x_t)$ 。根据贝叶斯定理

$$P(x_{t-1}|x_t) = \frac{P(x_t|x_{t-1})P(x_{t-1})}{P(x_t)} \quad (6)$$

利用前向扩散过程中推导得到的式(4)和式(5),将其代入式(6)并对各项进行整理,可以得出 $P(x_{t-1}|x_t)$ 服从如下正态分布

$$P(x_{t-1}|x_t) \sim N(\mu, \sigma^2) \quad (7)$$

其中,均值 $\mu$ 表示为

$$\mu = \frac{\sqrt{\alpha_t} (1 - \alpha_{t-1})}{1 - \bar{\alpha}_t} x_t + \frac{\sqrt{\alpha_{t-1}} (1 - \alpha_t)}{1 - \alpha_t} x_t - \frac{\sqrt{1 - \bar{\alpha}} \times \varepsilon}{\sqrt{\bar{\alpha}}} \quad (8)$$

其中, $\varepsilon$ 表示在任一时刻*t*直接加入最优解 $x_0$ 中的噪声。已知从 $x_0$ 到 $x_t$ 所添加的噪声 $\varepsilon$ 后,便可以确定前一时刻 $x_{t-1}$ 的概率分布。

而标准差 $\sigma$ 则为

$$\sigma = \sqrt{\frac{\sqrt{1 - \alpha_t} \sqrt{1 - \alpha_{t-1}}}{\sqrt{1 - \bar{\alpha}_t}}} \quad (9)$$

### 2.3 深度扩散确定性策略梯度算法

基于上述模型的反向扩散过程,可以训练一个神经网络,网络输入包括添加了噪声的解 $x_t$ ,用来预测添加到最优解 $x_0$ 中的噪声 $\varepsilon$ ,通过预测噪声,

就可以获得前一时刻解空间的概率分布。从该分布中随机采样生成前一时刻的解，然后将其再次输入到网络中预测其被添加的噪声，重复此过程直至获得期望的最优解 $x_0$ 。

通过训练神经网络持续执行有条件的反向扩散过程，将环境信息 $s_t$ 与加噪的解 $x_t$ 一起输入预测网络，最终获得的 $x_0$ 即为使用生成扩散模型优化的结果，也是D3PG策略网络输出的动作 $a_t$ 。

基于上述原理，D3PG算法如算法1所示。

#### 算法1 D3PG

初始化 $D$ 、 $Q(\theta^Q)$ 和 $\mu(\theta^\mu)$ ；

以相同权重初始化目标网络；

定义 $\Delta t$ 、 $T_{\max}$ 和 $\tau_{\max}$ ；

初始化Wi-Fi环境；

for  $T=1$  to  $T_{\max}$

从Wi-Fi环境中获取状态 $s_t$ ；

采样高斯噪声 $a_N$ ；

基于 $s_t$ 、 $a_N$ 和 $\tau_{\max}$ ，通过 $\mu(\theta^\mu)$ 推理动作 $a_t$ ；

if 训练模型 then

$a_t \leftarrow a_t + \text{noise}$

执行动作 $a_t$ 并观察 $r_t$ 和 $s_{t+1}$ ；

将轨迹 $r_t=(s_t, a_t, r_t, s_{t+1})$ 存入 $D$ ；

随机采样 $N$ 条轨迹；

基于采样的轨迹更新 $Q(\theta^Q)$ 和 $\mu(\theta^\mu)$ ；

更新目标网络；

end if

执行动作 $a_t$ ；

end for

其中， $D$ 表示经验回放池， $Q(\theta^Q)$ 和 $\mu(\theta^\mu)$ 分别表示评价网络和条件扩散模型策略网络， $\Delta t$ 表示交互周期， $T_{\max}$ 和 $\tau_{\max}$ 分别表示最大训练时间步数和最大噪声扩散步数。

### 3 仿真测试

为了评估D3PG算法的有效性，本文使用PyTorch实现了该算法，并在NS3平台上仿真实现了相应的Wi-Fi场景，其中，NS3是一个开源的离散事件网络仿真工具。为了将机器学习算法集成到Wi-Fi场景中并动态调整多个网络参数，使用了NS3-AI模块，NS3-AI作为NS3与PyTorch之间的接口。

仿真采用的Wi-Fi网络架构如图1所示，基于

802.11ax标准的相关机制进行设计。NS3仿真参数设置见表1，D3PG超参数设置见表2。

表1 NS3仿真参数设置

参数名称	参数值
STA数量	{8, 16, 24, 32, 40, 48, 56, 64}
载波频率	5 GHz
最大A-MSDU	6 160 byte
最大A-MPDU	1 586 176 byte
CW取值范围	[15, 1 023]
帧聚合度范围	[1, 256]
AP与STA之间距离	以AP为圆心,半径为7.5 m的圆内
仿真时间	100 s
路径损失模型	对数距离传播损耗模型
流量模型	固定速率模型,速率为1 Gbit/s
信道带宽	80 MHz
空间流数量	2
有效载荷	1 448 byte
流量类型	TCP流量
移动模型	固定位置模型

表2 D3PG超参数设置

参数名称	参数值
交互周期 $\Delta t$	50 ms
隐藏层节点数	256
奖励正则化系数 $\lambda$	450 Mbit/s
策略网络(Actor)学习率	0.002
评价网络(Critic)学习率	0.02
软更新系数	0.05
奖励折扣系数	0.1
批次大小	12
缓存大小	256
$\beta$ 调度	线性方差保持调度
扩散步数	5

在仿真过程中，本文首先比较了在64个STA场景下算法的吞吐量性能。选择了3种不同代表性算法作为性能对比基线算法。

基线1：采用现有802.11标准的MAC层DCF机制，并使用固定帧聚合长度。

基线2：由Schulman等<sup>[31]</sup>提出的近端策略优化(PPO, proximal policy optimization)算法，是一种基于策略的强化学习算法。

基线3：未结合GDM的DDPG算法，其部分超参数设置与本文D3PG算法相同。

基线2和基线3使用了与本文所提方法相同的状态、动作和奖励函数。需要注意的是，由于Wi-

Fi 网络的随机性，对每种算法进行了 5 次重复仿真，取其平均值以最小化随机性对比结果的影响。

不同算法总吞吐量对比如图 2 所示，D3PG 算法相较于基线 1、基线 2 和基线 3 吞吐量分别提升了 74.6%、13.5% 和 10.5%。




图 2 不同算法总吞吐量对比

在时延性能方面，不同算法平均时延对比如图 3 所示，D3PG 算法相较于基线 1 平均时延仅增加了 6.54 ms，由于 D3PG 算法没有将时延性能纳入奖励函数，且 TCP 类型流量对时延不敏感，D3PG 算法最终优化结果在只增加少量时延的情况下，大幅提升了吞吐性能，且时延表现均优于基线 2 和基线 3。具体而言，与基线 3 相比，D3PG 性能更优的主要原因是 GDM 的作用，其能够更准确地映射环境信息与动作组合之间的关系，从而在复杂场景中实现更精确的参数控制。




图 3 不同算法平均时延对比

图 4 展示了 D3PG 算法与基线 3 在训练过程中总吞吐量的变化情况，以及不同算法的收敛时间。可以看出，D3PG 算法的训练过程更加稳定，而基线 3 波动较大，且 D3PG 能够实现更高的吞吐量，这意味着其性能更优。这是因为 D3PG 具有更强的探索能力，能够使模型更快地达到最佳性能并减少

训练时间。因此，在快速变化的 Wi-Fi 环境中，如果模型因环境变化需要重新训练，D3PG 算法能够实现更快的收敛，将对用户体验的影响降至最低。




图 4 D3PG 算法与基线 3 在训练过程中总吞吐量的变化情况

D3PG 算法跟传统强化学习算法一样，有许多超参数需要设置，本文特别研究了其中最重要的超参数之一，即扩散步数的影响。对 D3PG 算法性能的影响如图 5 所示，扩散步数对 D3PG 算法的性能有明显影响。当扩散步数过少时，模型的学习推理能力不足，导致性能表现不佳。相反，过多的扩散步骤会增加计算资源的需求，并可能导致模型过拟合，最终降低性能。




图 5 扩散步数对 D3PG 算法性能的影响

最后，评估了在不同 STA 数量下 D3PG 算法与基线算法的吞吐量性能。不同 STA 数量场景吞吐量对比如图 6 所示，所有 STA 均匀分布在以 AP 为中心、半径为 7.5 m 的圆形区域内。D3PG 算法在所有网络规模下均表现出性能提升。对于基线 1，吞吐量最初随着用户数量的增加而上升，这是由于更多用户便有更高的流量需求，但随着 BSS 内竞争的加剧导致冲突增加，吞吐量最终下降，这凸显了 BEB 机制在密集场景中的局限性。相比之下，D3PG 算法在网络饱和时仍能实现稳定的吞吐量，吞吐量最初随着用户数量的增加而上升，在高竞争

环境下，吞吐量趋于稳定但未出现显著下降，这得益于D3PG算法的优化表现。

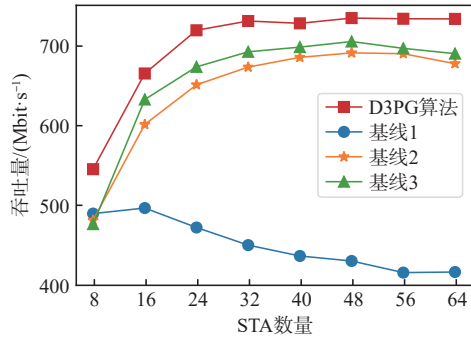


图6 不同STA数量场景吞吐量对比

## 4 结束语

本文提出了一种基于D3PG算法的MAC层接入机制，通过联合调整每个STA的竞争窗口和帧聚合长度来提升网络吞吐量。该机制有效解决了密集Wi-Fi场景中因BSS内竞争加剧导致的吞吐量性能急剧下降的问题，经过D3PG算法优化后，各种场景的吞吐量提升显著。此外，得益于GDM在复杂数据分布建模方面的优势，D3PG算法具有更稳定的训练过程、更快的收敛速度以及更强的灵活性和适应性。本文首次将生成式AI应用于优化Wi-Fi网络的MAC层表现，结果表明该方法能够有效提升性能。在未来的研究中，可以将D3PG算法框架拓展至多AP协作、移动终端动态接入等更复杂的场景，研究GDM对时变信道特性的建模能力，或探索MAC层参数与物理层波束成形、MIMO配置的协同优化机制等。

## 参考文献：


- [1] DENG C L, FANG X M, HAN X, et al. IEEE 802.11be Wi-Fi 7: new challenges and opportunities[J]. *IEEE Communications Surveys & Tutorials*, 2020, 22(4): 2136-2166.
- [2] MOZAFFARIAHRAR E, THEOLEYRE F, MENTH M. A survey of Wi-Fi 6: technologies, advances, and challenges[J]. *Future Internet*, 2022, 14(10): 293.
- [3] LOPEZ-PEREZ D, GARCIA-RODRIGUEZ A, GALATI-GIORDANO L, et al. IEEE 802.11be extremely high throughput: the next generation of Wi-Fi technology beyond 802.11ax[J]. *IEEE Communications Magazine*, 2019, 57(9): 113-119.
- [4] WANG J, HAO Y L, YANG C. The current progress and future prospects of path loss model for terrestrial radio propagation[J]. *Electronics*, 2023, 12(24): 4959.
- [5] VASUDEVAN M, YUKSEL M. Machine learning for radio propagation modeling: a comprehensive survey[J]. *IEEE Open Journal of the Communications Society*, 2024, 5: 5123-5153.
- [6] 伏玉笋, 杨根科. 人工智能在移动通信中的应用: 挑战与实践[J]. *通信学报*, 2020, 41(9): 190-201.  
FU Y S, YANG G K. Application of artificial intelligence in mobile communication: challenge and practice[J]. *Journal on Communications*, 2020, 41(9): 190-201.
- [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] SAI S, GARG A, JHAWAR K, et al. A comprehensive survey on artificial intelligence for unmanned aerial vehicles[J]. *IEEE Open Journal of Vehicular Technology*, 2023, 4: 713-738.
- [9] QUEIRÓS R, ALMEIDA E N, FONTES H, et al. Wi-Fi rate adaptation using a simple deep reinforcement learning approach[C]// *Proceedings of the 2022 IEEE Symposium on Computers and Communications (ISCC)*. Piscataway: IEEE Press, 2022: 1-3.
- [10] CROITORU F A, HONDRU V, IONESCU R T, et al. Diffusion models in vision: a survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(9): 10850-10869.
- [11] GOZALO-BRIZUELA R, GARRIDO-MERCHAN E C. ChatGPT is not all you need. A state of the art review of large generative AI models[EB]. 2023
- [12] EPSTEIN Z, HERTZMANN A, AKTEN M, et al. Art and the science of generative AI[J]. *Science*, 2023, 380(6650): 1110-1111.
- [13] JO A. The promise and peril of generative AI[J]. *Nature*, 2023, 614(1): 214-216.
- [14] URKUDE P, CHARDE D, PIDURKAR S, et al. Multi-domain content generation using advanced machine learning techniques[C]// *Proceedings of the 2024 ICT for Intelligent Systems*. Singapore: Springer, 2024: 541-551.
- [15] TRABUCCO B, DOHERTY K, GURINAS M, et al. Effective data augmentation with diffusion models[EB]. 2023.
- [16] DU H Y, ZHANG R C, LIU Y Q, et al. Enhancing deep reinforcement learning: a tutorial on generative diffusion models in network optimization[J]. *IEEE Communications Surveys & Tutorials*, 2024, 26(4): 2611-2646.
- [17] DU H Y, LI Z H, NIYATO D, et al. Diffusion-based reinforcement learning for edge-enabled AI-generated content services[J]. *IEEE Transactions on Mobile Computing*, 2024, 23(9): 8902-8918.
- [18] KHAN M A A, BEEN K, BIPLOB B. A study on delay, throughput and traffic measurement for Wi-Fi connected stations based on MAC sublayer[J]. *IEEE Communications Surveys & Tutorials*, 2019, 20(1): 197-216.
- [19] MANZOOR S, YIN Y C, GAO Y Y, et al. A systematic study of IEEE 802.11 DCF network optimization from theory to testbed[J]. *IEEE Access*, 2020, 8: 154114-154132.
- [20] LI Y, LV Z W, FAN Z H, et al. Adaptive two-step binary exponen-

- tial backoff strategy for random access[C]//Proceedings of the 2023 IEEE 6th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC). Piscataway: IEEE Press, 2023: 1104-1109.
- [21] UMEHARA D, YUAN J H. Success prioritized binary exponential backoff algorithm for non-persistent CSMA[C]//Proceedings of the 2019 IEEE Global Communications Conference (GLOBECOM). Piscataway: IEEE Press, 2020: 1-6.
- [22] BIANCHI G. Performance analysis of the IEEE 802.11 distributed coordination function[J]. IEEE Journal on Selected Areas in Communications, 2000, 18(3): 535-547.
- [23] SUZUKI K, YAMAZAKI S. Throughput maximization based on optimized frame-aggregation levels for IEEE 802.11 WLANs[J]. IEEE Communications Letters, 2021, 25(5): 1725-1728.
- [24] EL H B N, BUSSON A, RIVANO H. Analytical study of frame aggregation level to infer IEEE 802.11 network load[C]//Proceedings of the 2020 International Wireless Communications and Mobile Computing (IWCMC). Piscataway: IEEE Press, 2020: 952-957.
- [25] CAMPS-MUR D, GOMONY M D, PÉREZ-COSTA X, et al. Leveraging 802.11n frame aggregation to enhance QoS and power consumption in Wi-Fi networks[J]. Computer Networks, 2012, 56(12): 2896-2911.
- [26] CORONADO E, THOMAS A, RIGGIO R. Adaptive ML-based frame length optimisation in enterprise SD-WLANs[J]. Journal of Network and Systems Management, 2020, 28(4): 850-881.
- [27] ZHOU L H, FANG X M, HE R, et al. Deep reinforcement learning-based joint frame length and rate adaption for WLAN network[C]//Proceedings of the 2023 IEEE 98th Vehicular Technology Conference (VTC2023-Fall). Piscataway: IEEE Press, 2023: 1-5.
- [28] WANG D, HU M Q. Deep deterministic policy gradient with compatible critic network[J]. IEEE Transactions on Neural Networks

and Learning Systems, 2023, 34(8): 4332-4344.

- [29] AGGARWAL C C. Neural networks and deep learning: a textbook [M]. Cham: Springer, 2018.
- [30] HO J, JAIN A, ABBEEL P. Denoising diffusion probabilistic models[EB]. 2020.
- [31] SCHULMAN J, WOLSKI F, DHARIWAL P, et al. Proximal policy optimization algorithms[EB]. 2017.

#### [作者简介]



刘铁(1999–), 男, 西南交通大学信息科学与技术学院硕士生, 主要研究方向为 Wi-Fi 网络性能优化、Wi-Fi 标准。



方旭明(1962–), 男, 博士, 西南交通大学信息科学与技术学院教授, 主要研究方向为通信感知计算一体化网络、Wi-Fi 网络、智能交通移动通信系统。



何蓉(1974–), 女, 博士, 西南交通大学信息科学与技术学院副教授, 主要研究方向为 Wi-Fi 网络、无线资源分配、通信感知计算一体化网络。