



专题：无人机空地无线通信技术

无人机辅助无蜂窝大规模 MIMO 中的空地协同调度

邓丹昊¹, 王朝炜¹, 江帆², 王卫东¹

(1. 北京邮电大学电子工程学院, 北京 100876;

2. 西安邮电大学通信与信息工程学院, 陕西 西安 710121)

摘要: 无蜂窝大规模多输入多输出 (multiple-input multiple-output, MIMO) 技术采用大量接入点 (access point, AP) 为地面用户提供高效的通信服务, 但在有高速移动用户的场景中, 会加剧对信道状态信息的依赖。为了减少导频资源的消耗, 提出了一种综合无人机 (unmanned aerial vehicle, UAV) 辅助通信和无蜂窝大规模 MIMO 通信的双系统架构, 该架构能够预测高速移动用户的轨迹, 利用无人机为其提供可靠通信; 进一步提出了基于深度强化学习 (deep reinforcement learning, DRL) 的无人机轨迹设计和地面用户调度方案, 在满足各类约束的前提下实现系统总和速率最大化。仿真结果表明, 与现有方案相比, 所提方案能够有效提升系统容量。

关键词: 无蜂窝大规模 MIMO; 无人机辅助通信; 联合空地调度; 深度强化学习

中图分类号: TN915

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2022242

Coordinated air-ground scheduling for UAV-assisted cell-free massive MIMO

DENG Danhao¹, WANG Chaowei¹, JIANG Fan², WANG Weidong¹

1. School of Electronic Engineering, Beijing University of Posts and Telecommunications, Beijing 100876, China

2. School of Communication and Information Engineering, Xi'an University of Posts and Telecommunications, Xi'an 710121, China

Abstract: Cell-free massive multiple-input multiple-output (MIMO) technology uses a large number of access points (AP) to provide efficient communication services for terrestrial users. However, massive APs and users increase the demand for channel state information detection, especially for users with high moving speeds. In order to reduce the consumption of pilot resources, a dual system architecture that integrates unmanned aerial vehicle-assisted (UAV-assisted) communications and cell-free massive MIMO communications was proposed. The architecture was able to predict the movement trajectories of high-speed users and use UAVs to provide them with reliable communications. A UAV trajectory design and user scheduling scheme based on deep reinforcement learning (DRL) was further proposed, which maximized the system sum rate under the premise of satisfying various constraints. Simulation results demonstrate that the proposed scheme is able to predict user trajectories and improve system sum rate compared with existing schemes.

Key words: cell-free massive MIMO, UAV-assisted communication, coordinated air-ground scheduling, DRL

收稿日期: 2022-07-01; 修回日期: 2022-07-18

通信作者: 王朝炜, wangchaowei@bupt.edu.cn; 江帆, jiangfan@xupt.edu.cn

基金项目: 国家重点研发计划项目 (No. 2020YFB1807204)

Foundation Item: The National Key Research and Development Program of China (No.2020YFB1807204)



0 引言

大规模多输入多输出 (multiple-input multiple-output, MIMO) 是 6G 的核心技术之一, 具有大量天线的基站为占用相同时频资源的多个用户提供服务, 进一步提高了频谱效率、能量效率以及可靠性^[1-3]。根据天线阵列的部署情况, 可以将大规模 MIMO 系统定义为集中式或分布式。在分布式大规模 MIMO 系统中, 天线阵列被多个不同位置的接入点 (access point, AP) 所取代, 这些接入点自由分布在整个通信区域内。因此, 分布式系统可以利用空间多样性对抗阴影衰落, 与集中式系统相比具有更高的覆盖率。最近, 文献[4]提出了一种新的分布式系统: 无蜂窝大规模 MIMO。该系统没有小区和小区边缘的概念, 而是由一组分布式 AP 通过时分双工模式, 协同地服务于覆盖范围内的所有活动用户。AP 接收和传输的信号由中央处理器 (central processing unit, CPU) 采集、转发与处理。无蜂窝系统可以缓解小区间干扰对传统架构中用户的影响^[5], 从而提高系统性能。但是无蜂窝大规模 MIMO 也带来了严重的多用户干扰^[6-7]、不完美全局信道状态信息^[8]、复杂的资源分配^[8]等挑战。例如, 针对地面高速移动的用户, 无蜂窝大规模 MIMO 需要频繁地分配导频资源检测当前的信道状态信息, 因此会造成大量的资源消耗以及信息时延。

不需要部署固定基础设施就可以为地面用户提供通信服务, 无人机辅助通信技术被认为是一种很有发展前景的技术^[9-11], 从而广泛应用于覆盖增强、无线中继和信息传播等方面^[12-15]。尽管学术界对此高度重视, 但无人机辅助通信仍有许多问题亟待解决, 如无人机在高动态环境下的轨迹部署等。针对用户高速移动场景, 基于用户轨迹预测, 提前设计无人机轨迹, 可以减少无人机的响应时间, 从而为用户提供更高质量的服务^[16]。

文献[16]采用回声状态网络 (echo state network, ESN) 预测用户位置, 提出了一种多智能体 Q -learning 算法设计无人机轨迹。文献[17]提出了一种基于异步并行计算的深度确定性策略梯度 (deep deterministic policy gradient, DDPG) 算法对无人机轨迹进行优化。文献[18]构建了短期精确预测与长期粗预测相结合的框架, 并采用滚动优化方法获取无人机航迹。

本文针对无蜂窝大规模 MIMO 网络, 首先区分网络中的低速和高速用户, 分别构建无蜂窝通信架构和无人机辅助通信架构, 两种架构以时分复用的方式交替进行通信服务。在无人机辅助通信架构中, 本文将无人机轨迹设计建模为序列决策问题, 并进一步转化为马尔可夫决策过程 (Markov decision process, MDP), 基于深度强化学习 (deep reinforcement learning, DRL) 算法, 提出一种无人机轨迹预测及资源管理方案。

1 系统模型

本文讨论的无人机辅助无蜂窝大规模 MIMO 网络如图 1 所示, 系统包含 M 个 AP、 K 个用户、 N 架无人机, 以及一个 CPU。每个 AP 配置 L 根天线, 而用户和无人机则配置单根天线。CPU 通过不断发送导频信号检测用户的信道状态信息, 据此进行各类资源分配。由于地面用户的高速移动会改变用户与 AP 间的路径损失, 从而影响信道状态信息, CPU 需要频繁地为高速用户分配导频资源。因此, K 个用户根据移动速率划分为 K_l 个低速用户和 K_h 个高速用户, 其中 $K = K_l + K_h$ 。本文提出一种双系统架构, 其中由 M 个 AP 和 CPU 组成的无蜂窝系统服务 K_l 个低速用户, 由 N 架无人机组成的无人机辅助通信系统则服务 K_h 个高速用户。两系统通过时分复用模式交替进行通信服务, 同时 AP 与无人机占用不同的频段避免系统间干扰。




图1 无人机辅助无蜂窝大规模 MIMO 网络

1.1 无蜂窝大规模 MIMO 系统

首先, CPU 计算针对 K_1 个低速用户的波束成形信号, 并通过量化前传链路进行信号压缩。之后, CPU 将压缩后的信号转发到每个 AP。AP 端的接收信号可以表示为:

$$\mathbf{x}_m(t) = \sum_{k_1=1}^{K_1} \mathbf{w}_{m,k_1}(t) s_{k_1}(t) + \mathbf{c}_m(t) \quad (1)$$

其中, $\mathbf{w}_{m,k_1}(t) \in \mathbf{C}^{L \times 1}$ 表示用户 k_1 与 AP m 间的波束成形矩阵, $s_{k_1}(t)$ 表示用户 k_1 的下行期望信号, 该信号满足 $E[s_{k_1}^H(t)s_{k_1}(t)] = 1$, $\mathbf{c}_m(t) \in \mathbf{C}^{L \times 1}$ 为 AP m 受到的压缩噪声。各个 AP 将所接收的信号通过无线链路转发给所有的低速用户, 因此, 用户 k_1 的接收信号可以表示为:

$$y_{k_1}(t) = \mathbf{h}_{m,k_1}^H(t) \mathbf{x}_m(t) + \sum_{m'=1}^M \mathbf{h}_{m',k_1}^H \mathbf{x}_{m'}(t) + n_{k_1} \quad (2)$$

其中, $\mathbf{h}_{m,k_1}(t)$ 表示用户 k_1 与 AP m 间的信道状态信息矩阵, n_{k_1} 表示用户 k_1 受到的加性白高斯噪声 (additive white Gaussian noise, AWGN)。用户 k_1 的可达速率为:

$$R_{k_1}(t) = \text{lb} \left(\frac{|\mathbf{h}_{k_1}^H(t) \mathbf{w}_{k_1}(t)|^2}{\sum_{k'=1, k' \neq k_1}^{K_1} |\mathbf{h}_{k'}^H(t) \mathbf{w}_{k'}(t)|^2 + \sigma_{k_1}^2} \right) \quad (3)$$

其中, $\mathbf{h}_{k_1}(t) = [\mathbf{h}_{1,k_1}^T(t), \dots, \mathbf{h}_{M,k_1}^T(t)]^T \in \mathbf{C}^{LM \times 1}$ 表示用户 k_1 与所有 AP 间的信道状态信息矩阵, $\mathbf{w}_{k_1}(t) = [\mathbf{w}_{1,k_1}^T(t), \dots, \mathbf{w}_{M,k_1}^T(t)]^T \in \mathbf{C}^{LM \times 1}$ 表示用户 k_1

与所有 AP 间的波束成形矩阵, $\sigma_{k_1}^2$ 为用户 k_1 受到的 AWGN 功率。

所有低速用户的总和速率可以表示为:

$$R = \sum_{k_1=1}^{K_1} R_{k_1}(t) \quad (4)$$

1.2 无人机辅助通信系统

假设每个无人机通过时分复用服务不同的用户, 同时所有无人机共享相同的频段。为简单起见, 无人机飞行时长 T 被划分为 I 个时长相等的时隙点。在实际应用中, 空对地信道主要以视距 (line of sight, LoS) 链路为主。因此, 无人机 n 与高速用户 k_h 之间的信道增益遵循自由空间路径损失模型, 可以表示为:

$$h_{n,k_h}[i] = \beta_0 d_{n,k_h}^{-2}[i] = \frac{\beta_0}{\|\mathbf{q}_n[i] - \mathbf{u}_{k_h}[i]\|} \quad (5)$$

其中, β_0 表示表示参考距离 $d=1$ m 时的信道功率增益, $\mathbf{q}_n[i]$ 表示无人机 n 在时隙 i 的笛卡尔坐标, $\mathbf{u}_{k_h}[i]$ 则表示用户 k_h 在时隙 i 的笛卡尔坐标。当无人机 n 服务用户 k_h 时, 该用户的信干噪比 (signal to interference plus noise ratio, SINR) 为:

$$\text{SINR}_{n,k_h}[i] = \frac{p_n[i] h_{n,k_h}[i]}{\sum_{j=1, j \neq n}^N p_j[i] h_{j,k_h}[i] + \sigma_{k_h}^2} \quad (6)$$

其中, $p_n[i]$ 为无人机 n 在时隙 i 的发送功率, $\sigma_{k_h}^2$ 为高速用户 k_h 受到的 AWGN 功率。因此, 用户 k_h 在时隙 i 的可达速率为:

$$R_{k_h}[i] = \sum_{n=1}^N \alpha_{n,k_h}[i] \text{lb}(1 + \text{SINR}_{n,k_h}[i]) \quad (7)$$

其中, $\alpha_{n,k_h}[i]$ 为 0-1 变量, 表示用户调度。具体来说, 假设在一个时隙内, 每架无人机最多只能服务一个用户, 同时每个用户最多只能被一架无人机服务:

$$\sum_{k_h=1}^{K_h} \alpha_{n,k_h}[i] \leq 1 \quad (8)$$

$$\sum_{n=1}^N \alpha_{n,k_h}[i] \leq 1 \quad (9)$$

为了有效地提升系统内 AP 和无人机的协作



性能, 本文的目标是构建一个基于无人机轨迹设计和用户调度的总和速率最大化问题, 该问题的数学表达式为:

$$\begin{aligned} \max \quad & \bar{R} = \frac{1}{K_h} \sum_{i=1}^I \sum_{k_h=1}^{K_h} R_{k_h}[i] + \frac{1}{K_l} IR \\ \text{s.t.} \quad & \text{式 (8)、式 (9)} \end{aligned} \quad (10)$$

2 基于 DRQN 的无人机轨迹设计和用户调度方案

无人机轨迹设计问题属于序列决策问题, 该类问题通常需要联合求解数千个优化变量, 且变量间存在极强的相关性^[19]。因此, 本文将问题(10)建模为 MDP 并利用 DRL 算法进行求解。

2.1 MDP 模型

MDP 由 4 个部分组成, 分别为状态 s 、动作 a 、奖励 r 和动作选择策略 π 。具体来说, 智能体从系统中获得当前的状态 s , 并根据动作选择策略 π 决定当前动作 a 。在智能体执行动作 a 后, 系统会转变为下一状态 s' , 并通过反馈奖励 r 体现该状态—动作对的可行性和最优性。本文将地面 CPU 作为智能体来确定无人机的轨迹和用户调度。式(10)中的状态、动作和奖励分别如下。

- 状态: 系统状态包含所有影响高速用户轨迹预测和优化问题式(10)的变量。用户轨迹预测与用户当前位置、速度和加速度有关, 分别表示为 $l_{k_l}(i)$ 、 $v_{k_l}(i)$ 和 $a_{k_l}(i)$, 其中, 速度和加速度可以由过去 3 个时隙的位置推导。此外, 优化问题式(10)还与无人机的当前位置 $q_n[i]$ 以及当前的时隙 i 相关。
- 动作: 无人机轨迹设计和用户调度方案的动作包括两个部分。假设无人机在每个时隙内以固定的速度飞行, 其下一时刻位置仅取决于当前的飞行方向 $d_{k_l}(i)$; 同时, 用户调度可以用 $\alpha_{n,k_h}[i]$ 表示。
- 奖励: 奖励函数的目标是在满足约束(8)和约束(9)的前提下, 最大化系统总和速率。因此, 奖励函数被定义为:

$$r(i) = \xi_r(i)\bar{R} + \xi_c(i)\mu \quad (11)$$

其中, $\xi_r(i)$ 和 $\xi_c(i)$ 为 0-1 指示器, 一方面, 本文设置负奖励惩罚违反式(8)、式(9)的任何动作, 并利用 $\xi_c(i)=1$ 辅助判别; 另一方面, 当且仅当所有无人机到达目的地时, 即 $\xi_r(i)=1$ 时, 当前动作被赋予正向奖励 $\bar{R}$ 。值得注意的是, 无人机的轨迹设计需要在下一时刻得到反馈, 因此状态—动作对与奖励值存在时间上的不对应性。同时, 由于用户处于高速移动状态, 当前时刻的用户位置与下一时刻存在较大差异, $\bar{R}$ 需要根据下一时刻的用户位置与无人机位置进行计算。

2.2 DRQN 算法

DRL 的核心目标是通过不断与环境交互, 学习到最优的动作选择策略 π^* 。深度 Q 网络 (deep Q -network, DQN) 算法采用 Q 函数 $Q^\pi(s, a)$ 表示在状态 s 处采取动作 a 的潜在价值:

$$Q^\pi(s, a) = E \left[\sum_{\tau=0}^{\infty} \gamma^\tau r(s(\tau), a(\tau)) \mid s(0) = s, a(0) = a \right] = E [R(s, a) + \gamma Q^\pi(s', a')] \quad (12)$$

其中, $\gamma \in (0, 1]$ 为折扣因子, $R(s, a)$ 是在状态 s 处采取动作 a 的即时奖励, s' 和 a' 分别为下一时刻的状态和动作。理论上, 最优的动作 a^* 应该具有最大的潜在价值。因此, 可以根据 Q 函数寻找当前的最优动作:

$$a^* = \pi^*(s) = \arg \max_a Q^\pi(s, a) \quad (13)$$

DQN 通常采用两个深度神经网络 (deep neural network, DNN) 搭建 Q 函数。其中, 第一个 DNN 承担 Q 函数的作用, 被称为主网络, 网络输入为当前的状态 s , 输出为所有动作的 Q 值 $Q(s, a; \theta)$ 。第二个 DNN 用于更新主网络权重 θ , 被称为目标网络, 且目标网络的架构与主网络相同。DQN 采用经验回放机制更新权重。具体来说, 智能体将所经历的样本 (s, a, r, s') 存储到经验池中, 当存储样本达到最小容量时, 智能体随机采

样小批量的样本计算目标 Q 值:

$$Q_j^{\text{target}} = r_j + \gamma \max_{a_{j+1}} Q'(s_j, a_j | \theta') \quad (14)$$

其中, (s_j, a_j, r_j, s_{j+1}) 为第 j 个采样样本, θ' 表示目标网络的权重, $Q'(s, a; \theta')$ 为目标网络的输出 Q 值。本文利用随机梯度下降 (stochastic gradient descent, SGD) 法更新主网络的权重 θ 。更新的目标是使主网络输出 Q 值与目标 Q 值之间的时序差分误差 (temporal-difference error, TD error) 最小, 因此损失函数被定义为:

$$\text{Loss}(\theta) = \frac{1}{B} \sum_j \left[\left(Q_j^{\text{target}} - Q(s_j, a_j | \theta) \right)^2 \right] \quad (15)$$

其中, B 为采样的样本总数。损失函数式 (15) 相对于权重 θ 的梯度为:

$$\nabla_{\theta} \text{Loss}(\theta) = \frac{1}{B} \sum_j \left[\left(Q_j^{\text{target}} - Q(s_j, a_j | \theta) \right) \nabla_{\theta} Q(s_j, a_j | \theta) \right] \quad (16)$$

对于目标网络, 其权重更新不需要独立的损失函数与梯度, 而是每 N_t 步更新为主网络的权重 $\theta \rightarrow \theta'$ 。

为了同步实现高速用户的轨迹预测和资源优化, 本文在 DQN 的输入层和全连接层之间插入了一个长短期记忆 (long short-term memory, LSTM) 层, 将 DQN 发展为深度循环 Q 网络 (deep recurrent Q -network, DRQN)。其中, LSTM 层负责用户轨迹预测, 而全连接层根据输入状态和预测结果决定当前最优动作。

具体的算法流程如下。

步骤 1 初始化主网络、目标网络、记忆池、高速用户位置和移动方式、低速用户位置和移动方式。

步骤 2 初始化无人机的起始位置并生成初始状态 $s(0)$ 。

步骤 3 根据 ε -greedy 策略选择当前动作 $a(i)$ 。

步骤 4 执行动作 $a(i)$, 获得当前奖励 $r(i)$ 和下一状态 $s(i+1)$ 。

步骤 5 计算目标 Q 值, 更新主网络和目标网络。

步骤 6 重复步骤 3~步骤 5, 直到无人机抵达目的地。

步骤 7 重复步骤 2~步骤 6, 直到训练步数满足要求。

3 仿真结果与分析

3.1 仿真参数

在仿真中, 系统为 $1 \text{ km} \times 1 \text{ km}$ 的正方形区域, 包含 100 个 AP、80 个低速用户、5~10 个高速用户、2 架无人机和一个 CPU。无人机的飞行高度为 100 m, 最大飞行速度为 20 m/s, 最大发送功率为 30 dBm。高速用户的最大移动速度为 10 m/s。AP 的最大发送功率为 30 dBm。无蜂窝大规模 MIMO 系统进行通信服务时, AP 为其覆盖范围内的所有用户平均分配、发送功率。AP 与低速用户之间的信道状态信息综合考虑路径损失、阴影衰落等因素, 具体的参数参考文献[20]。无人机辅助通信系统与无蜂窝大规模 MIMO 的通信时间占比为 1:1。DRQN 算法采用 4 层网络结构, 学习率为 0.000 5, 折扣因子设定为 0.9, 经过 600 个周期的训练获得最终的动作选择策略。

3.2 仿真结果

本文所提基于 DRQN 的无人机轨迹设计和用户调度方案的收敛性能如图 2 所示。具体而言, DRQN 的收敛性由损失函数和系统性能两方面决定。损失函数可以表示 DRQN 内部神经网络的训练程度。理论上, 损失函数会随着训练的不断进行而下降, 最终趋于平稳; 然而仅利用损失函数表征方案的收敛性是不充分的, 这是因为神经网络的收敛并不能保证所提方案收敛到最优策略, 依旧存在方案收敛到局部最优的可能性。系统性能则表示 DRQN 方案是否有稳定的输出结果。随着训练的进行, 系统性能会不断上升直至稳定。同样, 由于无法确定是否有更优性能, 方案的收敛性不能仅利用系统性能曲线表征, 因此, 本文同时考虑损失函数和系统性能, 利用两者的训练



曲线说明方案的收敛性。可以看出, 两条曲线在经历 400 个周期训练后基本稳定, 可以认为方案已经收敛。




图2 基于DRQN的无人机轨迹设计和用户调度方案的收敛性能

不同的高速移动用户数量下, 不同方案的复杂度对比如图3所示。本文采用平均运行时间表征方案复杂度。仿真结果显示, 所提出的DRQN方案与其他方案相比, 复杂度显著降低。这是因为DRQN中的神经网络能够有效地处理状态—动作空间。对于Q-learning方案和贪婪方案, 随着用户数的提升, 两种方案需要面对的状态、动作数均呈指数增长。相应地, 两种方案需要更多的时间遍历所有可能的动作, 因此方案复杂度以较快的速度上升。为了得到与DRQN方案相似的性能, DQN方案的算法主体采用4层网络, 且网络各层均为全连接层; 然而, 全连接层数的增加以及神经元数的增长不仅会带来性能的提升, 也会使得方案的复杂度升高。




图3 不同的高速移动用户数量下, 不同方案的复杂度对比

不同高速用户数下的系统总和频谱利用率对比如图4所示, 所提DRQN方案的性能略高于贪婪方案, 且明显优于其他3种方案。随着用户数的增长, DRQN方案的优势也随之增加。对于高速移动用户, 计算系统总和速率 $\bar{R}$ 所需要的用户位置信息并不在系统状态中, 而是需要根据系统状态进行预测。DRQN中的LSTM层能够准确预测当前状态 s 和下一状态 s' 对应的用户位置, 并将完整信息传递给相邻的全连接层, 从而促使方案获得更佳的动作选择策略。循环神经网络(recurrent neural network, RNN)+DRL方案虽然能够有效预测当前状态 s 对应的用户位置, 但是序列决策问题不仅需要当前的完整状态, 还需要下一时刻的完整状态; 也就是说, 仅提供当前时刻的预测信息不足以支撑后续的DRL网络进行准确预测, 因此, 该对比方案的性能相较所提方案有所降低。此外, DQN算法仅由全连接层构成, 无法预测高速用户的移动轨迹, 只能根据当前时刻的用户位置信息进行动作选择, 因此会造成一定的性能降低。与图3中的原因相同, Q-learning方案无法处理巨大的状态—动作空间, 有限的学习经验使得其性能显著降低。




图4 不同高速用户数下的系统总和频谱利用率对比

不同高速用户轨迹数下的系统总和频谱利用率如图5所示。假设高速用户沿着固定的轨迹移动, 但每隔一段时间会更换移动轨迹。与图4相似, 所提DRQN方案性能略优于贪婪方案。同时,

随着可选轨迹的增多, 高速用户的轨迹预测难度也不断提升, 使得 RNN+DRL 方案、DQN 方案和 Q-learning 方案逐步失去自身的算法优势。




图5 不同高速用户轨迹数下的系统总和频谱利用率

4 结束语

本文针对无人机辅助无蜂窝大规模 MIMO 网络, 提出了一种双系统架构, 将用户划分为低速用户和高速用户, 无蜂窝大规模 MIMO 系统服务低速用户, 无人机辅助通信系统服务高速用户, 针对系统总和速率最大化目标, 构建了基于高速用户轨迹预测的无人机轨迹设计和用户调度问题。本文进一步将问题转化为 MDP, 并提出一种 DRQN 方案解决序列决策优化问题, 其中的 LSTM 层预测高速用户移动轨迹, 全连接层学习最优动作选择策略。仿真结果表明, 所提 DRQN 方案相较于传统的 RNN+DRL 方案、DQN 方案、Q-learning 方案和贪婪方案, 具有显著的性能提升。在今后的工作中, 笔者将研究无人机在三维坐标下的飞行模式, 通过精准的轨迹设计提升系统的通信能力。

参考文献:

- [1] LARSSON E G, EDFORS O, TUFVESSON F, et al. Massive MIMO for next generation wireless systems[J]. IEEE Communications Magazine, 2014, 52(2): 186-195.
- [2] WU Y P, KHISTI A, XIAO C S, et al. A survey of physical layer security techniques for 5G wireless networks and challenges ahead[J]. IEEE Journal on Selected Areas in Communi-

- cations, 2018, 36(4): 679-695.
- [3] ZHAO N, YU F R, LEUNG V CM. Opportunistic communications in interference alignment networks with wireless power transfer[J]. IEEE Wireless Communications, 2015, 22(1): 88-95.
- [4] NGO H Q, ASHIKHMIN A, YANG H, et al. Cell-free massive MIMO versus small cells[J]. IEEE Transactions on Wireless Communications, 2017, 16(3): 1834-1850.
- [5] ZHANG J Y, BJÖRNSON E, MATTHAIU M, et al. Prospective multiple antenna technologies for beyond 5G[J]. IEEE Journal on Selected Areas in Communications, 2020, 38(8): 1637-1660.
- [6] SHAKYA I L, ALI F H. Joint access point selection and interference cancellation for cell-free massive MIMO[J]. IEEE Communications Letters, 2021, 25(4): 1313-1317.
- [7] INTERDONATO G, KARLSSON M, BJÖRNSON E, et al. Local partial zero-forcing precoding for cell-free massive MIMO[J]. IEEE Transactions on Wireless Communications, 2020, 19(7): 4758-4774.
- [8] MATTHAIU M, YURDUSEVEN O, NGO H Q, et al. The road to 6G: ten physical layer challenges for communications engineers[J]. IEEE Communications Magazine, 2021, 59(1): 64-69.
- [9] ZHAO N, LU W D, SHENG M, et al. UAV-assisted emergency networks in disasters[J]. IEEE Wireless Communications, 2019, 26(1): 45-51.
- [10] 陈新颖, 盛敏, 李博, 等. 面向 6G 的无人机通信综述[J]. 电子与信息学报, 2022, 44(3): 781-789.
- CHEN X Y, SHENG M, LI B, et al. Survey on unmanned aerial vehicle communications for 6G[J]. Journal of Electronics & Information Technology, 2022, 44(3): 781-789.
- [11] PANG X W, GUI G, ZHAO N, et al. Uplink precoding optimization for NOMA cellular-connected UAV networks[J]. IEEE Transactions on Communications, 2020, 68(2): 1271-1283.
- [12] ZENG Y, ZHANG R, LIM T J. Wireless communications with unmanned aerial vehicles: opportunities and challenges[J]. IEEE Communications Magazine, 2016, 54(5): 36-42.
- [13] ZENG Y, ZHANG R. Energy-efficient UAV communication with trajectory optimization[J]. IEEE Transactions on Wireless Communications, 2017, 16(6): 3747-3760.
- [14] JIANG X, WU Z L, YIN Z D, et al. Joint power and trajectory design for UAV-relayed wireless systems[J]. IEEE Wireless Communications Letters, 2019, 8(3): 697-700.
- [15] ZHAO N, LI Y X, ZHANG S, et al. Security enhancement for NOMA-UAV networks[J]. IEEE Transactions on Vehicular Technology, 2020, 69(4): 3994-4005.
- [16] LIU X, LIU Y W, CHEN Y, et al. Trajectory design and power control for multi-UAV assisted wireless networks: a machine learning approach[J]. IEEE Transactions on Vehicular Technology, 2019, 68(8): 7957-7969.
- [17] ZHANG R, WANG M, CAI L X, et al. Learning to be proactive: self-regulation of UAV based networks with UAV and user dy-




- namics[J]. IEEE Transactions on Wireless Communications, 2021, 20(7): 4406-4419.
- [18] LIU Z N, HUANG G F, ZHONG Q H, et al. UAV-aided vehicular communication design with vehicle trajectory's prediction[J]. IEEE Wireless Communications Letters, 2021, 10(6): 1212-1216.
- [19] DING R J, GAO F F, SHEN X S. 3D UAV trajectory design and frequency band allocation for energy-efficient and fair communication: a deep reinforcement learning approach[J]. IEEE Transactions on Wireless Communications, 2020, 19(12): 7796-7809.
- [20] XIA X J, ZHU P C, LI J M, et al. Joint user selection and transceiver design for cell-free with network-assisted full duplexing[J]. IEEE Transactions on Wireless Communications, 2021, 20(12): 7856-7870.

[作者简介]



邓丹昊（1996-），女，北京邮电大学电子工程学院博士生，主要研究方向为无线资源管理技术。



王朝伟（1982-），男，博士，北京邮电大学电子工程学院副教授，主要研究方向为下一代移动通信技术、无线传感器与IoT技术等。



江帆（1982-），女，博士，西安邮电大学通信与信息工程学院教授，主要研究方向为基于人工智能的边缘计算及缓存技术、D2D通信技术、5G超密集异构网络中的无线资源管理等。



王卫东（1967-），男，博士，北京邮电大学电子工程学院教授，主要研究方向为卫星移动通信、下一代移动通信技术、IoT技术等。