



研究与开发

基于多智能体强化学习的可移动基站智能规划与优化

赵欣然, 陈美娟, 袁志伟, 朱晓荣

(南京邮电大学通信与信息工程学院, 江苏 南京 210003)

摘要: 为了在城市环境中快速部署可移动基站并实现运维优化, 针对终端用户移动带来的网络覆盖率下降问题与密集部署基站带来的干扰问题, 提出了一种基于多智能体强化学习的网络覆盖规划与优化方法。在部署阶段, 使用粒子群与果蝇混合优化算法, 在建站成本最小化的情况下确定基站最优站址; 在运维阶段, 设计了多智能体深度确定性策略梯度算法与轻量级梯度提升机算法的联合优化算法, 根据终端接收信号强度优化站址, 在性能指标仍无法达到要求时, 能自动在合适位置新增基站。仿真结果表明, 所提出的站址规划算法在覆盖率与服务率方面均优于传统启发式算法; 所设计的联合运维优化算法在网络覆盖率恢复能力方面优于传统 k 均值(k -means)聚类算法, 并且能适应更多场景。

关键词: 可移动基站; 站址; 规划; 优化; 多智能体强化学习

中图分类号: TN925

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2025035

Intelligent deployment and optimization of movable base stations based on multi-agent reinforcement learning

ZHAO Xinran, CHEN Meijuan, YUAN Zhiwei, ZHU Xiaorong

School of Communication and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

Abstract: To enable the rapid deployment of mobile base stations and optimize operations in urban environments, a network coverage planning and optimization method based on multi-agent reinforcement learning was proposed. This method was designed to address the issue of reducing network coverage due to user mobility and the interference caused by densely deployed base stations. During the deployment phase, a hybrid optimization algorithm combining particle swarm and fruit fly optimization was employed to determine the optimal base station locations while minimizing construction costs. In the operational phase, a joint optimization algorithm featuring multi-agent deep deterministic policy gradient and lightweight gradient boosting algorithms was designed to optimize base station locations based on terminal signal strength. Additionally, when performance indicators failed to meet requirements, new base stations

收稿日期: 2024-10-03; 修回日期: 2025-01-27

通信作者: 陈美娟, chenmj@njupt.edu.cn

基金项目: 江苏省科技计划重点项目 (No.BE2021013-2)

Foundation Item: The Key Project of Science and Technology Plan of Jiangsu Province (No.BE2021013-2)

were automatically added in suitable locations. Simulation results demonstrate that the proposed algorithm outperforms traditional heuristic algorithms in terms of coverage and service rates, while the designed joint operational optimization algorithm shows superior recovery capability in network coverage compared to the traditional k -means clustering algorithm, adapting to a wider range of scenarios.

Key words: movable base stations, base station location, planning, optimization, multi-agent reinforcement learning

0 引言

5G 技术在自动驾驶、智能交通、智慧医疗与虚拟现实方面的应用趋于成熟。相较于传统的通信技术，其拥有更高的传输速率、更低的传输时延、更大的传输带宽，可为用户带来更好的通信体验。但是，5G 技术使用了更高频的电磁波作为传输载体，这使得 5G 基站的覆盖范围远小于 4G 基站，在遮挡严重的大中型城市，往往需要部署更多的 5G 基站才能满足网络覆盖需求。固定式密集部署的 5G 基站不仅成本昂贵，而且会带来更加严重的干扰问题，这急需新的基站规划方法加以解决。在未来的 6G 技术中，城市中的部分基站将被部署在车辆或者无人机之上形成可移动基站，可移动基站可以根据终端用户的实时地理位置及时调整自身站址。基于此技术，未来有望提供更广泛、更可靠的网络覆盖，改善偏远地区与移动性较高的场所的通信质量。

为了实现上述需求，一套完整的基站部署及运维优化方案必不可少。在已有的文献中，基站站址规划问题已经得到广泛的讨论。其中，元启发式优化算法是一种较为经典的算法。文献[1]考虑了网络的覆盖与容量需求，采用模拟退火算法求解微基站最优站址与发射功率，提升了网络吞吐量。文献[2]考虑了基站之间的相互干扰问题，并使用灰狼优化算法与粒子群优化（particle swarm optimization, PSO）算法进行覆盖优化，降低了通信中断率。然而，传统启发式算法往往易陷入局部最优解，导致求解的基站站址并非最优站址，并且由于粒子数量固定不变，无法对基

站数量进行优化。为了解决该问题，文献[3]与文献[4]采取了遗传算法进行站址规划，此算法具有一定的跳出局部最优能力，使站址规划结果更加精确，但是相对增加了算法复杂度，在基站数目较多时计算速度显著变慢。文献[5]提出了自适应变长粒子群优化（adaptive variable-length PSO, AVLPSO）算法，此算法改善了算法的迭代公式，使学习权重动态增大以解决早熟问题，并且算法可以动态地增加与减少基站数量。不过在上述算法中，常常将基站的覆盖范围定义为圆形区域，这与现实中的基站覆盖情况严重不符，在地形复杂且遮挡众多的城市场景中并不适用^[6]。为了解决这一问题，聚类算法采用基于数据的思维进行站址规划。文献[7]和文献[8]使用了 k 均值（ k -means）聚类算法进行站址规划，此类算法的核心是根据地理位置对终端进行分簇，将基站部署在终端簇的中心，最大范围地为终端提供服务，并且基站可以根据终端的实时数据及时调整它的位置，实现运维优化。为了使站址规划结果更加准确，文献[9]引入了监督学习算法对终端信号强度进行预测，聚类算法根据终端信号强度进行站址优化，实现了网络覆盖率的及时恢复。但是，这种算法常导致簇边缘地区出现覆盖空洞，并且聚类算法对数据的要求极其严苛、对基站初始位置十分敏感，基站初始站址不佳将导致算法难以收敛。

为解决上述问题，文献[10]提出使用强化学习解决聚类算法存在的覆盖空洞。强化学习可以设置合理的奖励函数调控基站站址，减少基站之间的干扰，但是其单智能体 Q 学习只能采用轮训



的方式优化站址, 导致智能体之间不能相互配合, 收敛速度大大降低。文献[11]提出使用深度Q网络 (deep Q-network, DQN) 优化站址, 此方法通过设置全局奖励函数统一调配智能体的动作, 并且设置通信空间加速算法收敛, 在站址优化精确度和速度方面具有显著优势。但是其所采用的DQN算法属于基于价值的强化学习, 其动作空间具有离散性, 规划的站址结果不精确, 并且其使用的基站覆盖模型仍是传统的圆盘模型, 与现实基站覆盖区域不符。

综上所述, 传统的启发式算法具有计算速度快、对数据集规模要求低的优势, 适用于缺少网络精确数据并要求快速部署网络的初始部署阶段。强化学习算法的优势在于可以通过设置合理的奖励函数与通信空间, 引导智能体相互配合协作, 消除覆盖空洞, 更好地恢复网络健康, 并且可以跟随实时数据进行优化。此类算法更适合于运维优化阶段, 但目前存在适用场景受限问题^[12]。为解决上述问题, 本文提出了一种基于多智能体强化学习 (multi-agent reinforcement learning, MARL) 的可移动基站规划与优化方法。该方法分为2个阶段: 初始部署阶段与运维优化阶段。初始部署阶段, 场景设置在未搭建通信网络的城市区域, 通过对区域中的用户需求进行分析, 将建站问题建模为最优化问题。为了在缺少详细数据的情况下快速得到最优站址, 此阶段选择粒子群混合果蝇算法进行求解。运维优化阶段, 场景设置在搭建了可移动通信系统的城市区域。此阶段选择基于价值与策略的强化学习算法, 以更加精确地计算基站站址, 并配合轻量级梯度提升机 (light gradient boosting machine, LightGBM) 算法计算基站覆盖面积, 使计算结果更加真实。综上所述, 本文主要研究工作如下。

(1) 为解决传统算法部署站址非最优问题, 基于粒子群与果蝇混合优化算法, 设计初始站址规划方法。具体而言, 分析研究区域终端用户的

覆盖需求与容量需求, 进行网络需求估算, 并将基站部署问题建模为一个最优化问题, 在建立最少基站的情况下, 通过此算法求解优化问题, 最终得到初始建站位置。

(2) 为解决可移动基站运维优化过程中终端簇边缘地区覆盖不佳问题, 基于多智能体深度确定性策略梯度 (multi-agent deep deterministic policy gradient, MADDPG) 算法^[13]设计站址优化模块。具体而言, 基于实时网络数据, 设置合理的通信空间与奖励函数, 使可移动基站协作式寻找网络中的覆盖空洞, 互相覆盖彼此的簇边缘地区, 实现网络状况的实时分析与网络覆盖健康的动态维护。

(3) 为解决基站传统覆盖模型不精确问题, 在运维优化阶段, 基于LightGBM算法, 设计终端信号强度预测模块。具体而言, 通过收集的网络数据集, 训练LightGBM监督学习模型, 使用该模型预测终端接收信号强度作为判断终端是否被覆盖的标准, 代替传统布尔覆盖模型。该模型将被用于与基站站址优化模块进行交互, 在覆盖率不佳时, 增加基站数量并重新进行站址优化。

1 系统模型与架构设计

在大中型城市中, 携带终端设备的用户十分密集, 蜂窝网络通过部署多个建立在车辆或者无人机上的可移动基站来实现用户之间的通信。可移动基站规划优化场景如图1所示。由于城市面积较大, 往往可以根据功能将城市划分为人口密度不同的区域, 比如人员密集的商务中心与人员稀疏的偏远郊区。本文设城市可划分为 L 个人员密集程度不同的区域, 所有区域中共存在 M 个终端用户与 N 个可移动基站, 用户接入距离其最近的可移动基站获得通信。其中, 区域集合使用 K 表示, 用户集合使用 I 表示, 可移动基站集合使用 J 表示。




图1 可移动基站规划优化场景

1.1 用户模型

在真实复杂的城市蜂窝网络通信环境中，携带终端设备的用户呈现出明显的动态性，主要体现在终端用户自身位置的实时变化，即单位时间内到达区域 k 的用户数量在实时变化。假设每个区域内的用户数量服从参数不同的泊松分布，即在区域 k 中，用户到达数量服从参数为 λ_k 的泊松分布，则有：

$$p(\rho_k) = \frac{(\lambda_k s S_k)}{\rho_k!} \exp(-\lambda_k s S_k) \quad (1)$$

其中， S_k 为区域 k 的面积； s 为时间跨度； ρ_k 是时间段 s 内到达区域 k 的用户数； $(0, t]$ 时间内区域 k 的平均用户数量为 $\lambda_k s S_k$ ，其中 t 为任意时刻。

单位时间区域 k 的用户数为：

$$M_k = \lambda_k S_k \quad (2)$$

1.2 地面传输模型

路径损耗是衡量信号传播距离的关键指标，进而影响对基站覆盖范围的判断。地面传输模型的准确与否关乎基站规划是否合理。然而，传输模型在不同频段与不同地形上会表现出较大的差异。传统无线传输模型 Okumura-Hata^[14]与 COST-231-Hata^[15]主要应用于 2 GHz 以下的低频段，在 5G 通信系统中采用的 6 GHz 以下低频段与 24 GHz 以上的高频段并不适用。鉴于此，本文选取 3GPP 36.873 协议定义的 Ura 传输模型，此模型

的频率范围适用于 0.5~100 GHz，并且适用于建筑物比较密集的城市区域，更加符合当下及未来的建站场景。具体传输模型如下。

$$\begin{aligned} L_P = & 161.04 - 7.1 \lg w_{\text{str}} + 7.5 \lg h_{\text{build}} + \\ & 20 \lg f_c - \left(24.37 - 3.7 \left(\frac{h_{\text{build}}}{h_{\text{BS}}} \right)^2 \right) \lg h_{\text{BS}} + \\ & (43.42 - 3.1 \lg h_{\text{BS}}) (\lg d_{ij} - 3) - \\ & \left(3.2 (\lg 17.625)^2 - 4.97 \right) - 0.6 (h_{\text{AP}} - 1.5) \end{aligned} \quad (3)$$

其中， L_P 为路径损耗； w_{str} 为平均街道宽度，范围为 5~50 m； h_{build} 为平均建筑物高度，范围为 5~50 m； h_{BS} 为发射台天线绝对高度，默认取值 25 m； d_{ij} 为发射台与接收机之间的距离； h_{AP} 为终端天线绝对高度，默认取值 1.5 m； f_c 为基站发射频率，范围为 0.5~100 GHz^[16]。

1.3 基站规划优化方法

基于上述用户模型与地面传输模型，设计了一种可移动基站规划优化方法，如图 2 所示。基站规划优化方法分为 2 个阶段，分别是基于粒子群与果蝇混合优化算法的初始部署阶段与基于 LightGBM 算法与 MADDPG 算法联合的运维优化阶段。初始部署阶段通过网络规模估算，分析移动用户覆盖需求与容量需求，求解优化问题得到初始基站的建站数量与部署位置。运维优化阶段通过 MADDPG 算法优化基站站址，恢复网络覆盖率，并通过 LightGBM 算法预测终端信号强度。若当前网络仍存在覆盖空洞，则增加可移动基站重新进行优化，直至恢复网络覆盖健康。此外，初始部署阶段与运维优化阶段也具有一定联系，初始部署阶段所计算得出的基站部署方案将作为运维优化阶段的输入信息，以模拟在未建站的区域建立通信网络与运维优化的完整过程。

2 初始部署阶段

此阶段，场景设立在未建立通信网络的区域，需要对研究区域进行分析，根据区域功能




图2 可移动基站规划优化方法

的不同,将研究区域划分为若干人口密度不同的小区域。由于此阶段无法获知用户精确地理位置,因此需使用用户模型模拟用户分布。此阶段采用信干噪比(signal to interference plus noise ratio, SINR)作为指标判断终端覆盖情况,以最小化建站成本为目标,通过粒子群与果蝇混合优化算法,规划建站数量与基站站址。

2.1 网络规模估算

良好的网络规模估算可以缩小求解的区间,显著加快求解速度。网络规模估算即估算所需站点数,包括覆盖需求与容量需求两个方面。

2.1.1 覆盖需求估算

覆盖需求估算需要将链路预算与传输模型结合,计算基站的覆盖半径,从而通过基站覆盖面积与研究区域面积确定所需的站点数。基于本文选取的地面传输模型,如式(3)所示,假设用户下行链路最大允许路径损耗为 γ_{Lp} ,计算达到此损耗时,基站与终端之间的距离,并将此距离设置为基站最大覆盖半径:

$$R_{BS} = \{L_P(d_{ij}) = \gamma_{Lp}\} \quad (4)$$

初始部署阶段,基站覆盖面积默认近乎为圆

形区域,且满足布尔覆盖模型,则基站覆盖面积为:

$$S_{BS} = \pi R_{BS}^2 \quad (5)$$

若终端用户在基站的覆盖半径之内,则认为用户通过此基站获取服务。已知研究区域总面积为 S_A ,基站覆盖面积为 S_{BS} ,为了确保所有小区域均被覆盖,所需要基站的数量为:

$$N_{cov} = \frac{S_A}{S_{BS}} \quad (6)$$

2.1.2 容量需求估算

容量需求估算,即根据单个基站所能提供的通信资源与用户的通信需求计算出满足通信容量需求的站点数。假设已知用户需求最低下行用户目标速率为 R_{th} ,小基站的通信容量为 C_{BS} ,则一个小基站最多能服务的用户数为:

$$M_{cap} = \frac{C_{BS}}{R_{th}} \quad (7)$$

为了满足研究区域内全部用户的数据传输速率需求,所需基站数量为:

$$N_{cap} = \frac{\sum_{k=1}^L M_k}{M_{cap}} \quad (8)$$

综合考虑覆盖需求估算与容量需求估算的结

果, 研究区域内网络规模估算的站点数应取值为两者的最大值, 即:

$$N_{BS} = \max \{N_{cov}, N_{cap}\} \quad (9)$$

2.2 优化问题形成

由于此阶段终端用户的精确地理位置未知, 并且大中型城市区域基站数目较多, 在小区边缘地区易产生重叠覆盖, 此阶段采用 SINR 作为终端被覆盖的标准。设基站的发射功率为 P_{BS} , 则终端 i 的接收功率为:

$$\frac{P_{BS} h_{ij}}{L_P(d_{ij})} \quad (10)$$

其中, h_{ij} 是信道增益, 其服从参数为 1 的指数分布, 即 $h_{ij} \sim \exp(1)$ 。

本文将干扰设置为除了终端 i 接入的基站外, 其他基站对终端 i 产生的干扰总和, 则终端 i 的下行链路 SINR 可以表示为:

$$R_{SIN}^i = \frac{P_{BS} h_{ij}}{L_P \left(\sum_{j'=1, j' \neq j}^{N_{BS}} I_{jj'} + \sigma^2 \right)} \quad (11)$$

其中, j' 表示除主基站 j 外的其他基站; σ^2 表示均值为 0、方差为 σ^2 的加性高斯噪声; $I_{jj'}$ 表示基站 j 与 j' 之间的干扰值。

定义一个二进制变量 γ_{ij} 表示终端 i 是否被覆盖:

$$\gamma_{ij} = \begin{cases} 1, R_{SIN} \geq R_{SIN}^0 \\ 0, \text{其他} \end{cases} \quad (12)$$

其中, R_{SIN}^0 表示 SINR 的阈值, 大于该阈值的终端被认为信号强度良好。设定每个终端至少被一个基站覆盖, 因此有如下覆盖约束:

$$\sum_{j=1}^{N_{BS}} \gamma_{ij} \geq 1, \forall i \in I \quad (13)$$

在现实网络规划场景下, 一个基站的覆盖面积可能包含数个区域, 基站应为其覆盖的所有用户提供服务。基站覆盖范围与区域相交面积如图 3 所示。定义 S_{kj} 为基站 j 的覆盖范围与区域 k 的相交面积, 并定义 φ_{kj} 表示相交面积占基站

覆盖面积的比例, 即:

$$\varphi_{kj} = \frac{S_{kj}}{S_{BS}} \quad (14)$$




图3 基站覆盖范围与区域相交面积

由式 (7) 可知, 一个基站能服务的用户数为 M_{cap} , 则基站 j 在区域 k 中服务的用户数量为 $M_{cap} \varphi_{kj}$ 。由于每个用户至少应通过一个基站获取服务, 则所有基站在区域 k 中提供的容量要大于区域 k 的用户数 u_k , 即满足如下容量约束:

$$\sum_{j=1}^{N_{BS}} M_{cap} \varphi_{kj} \geq u_k \quad (15)$$

在上述覆盖约束式 (12) 与容量约束式 (15) 的基础上, 以最小化建站数量、节约建站成本为目标, 构建如下站址优化问题:

$$\begin{aligned} \min_{N_{BS}, L_j, B_j} & \sum_{j=1}^{N_{BS}} \varepsilon_j \\ \text{s.t.} & \begin{cases} \text{C1: } \sum_{j=1}^{N_{BS}} \gamma_{ij} \geq 1 \\ \text{C2: } \sum_{j=1}^{N_{BS}} M_{cap} \varphi_{kj} \geq u_k \\ \text{C3: } (L_j, B_j) \in A, \forall j \in J \end{cases} \end{aligned} \quad (16)$$

其中, (L_j, B_j) 表示基站 j 的经纬度; ε_j 是一个二进制变量, 用于表示基站 j 是否被部署, 具体定义如下。



$$\varepsilon_j = \begin{cases} 1, \text{基站}j\text{被部署} \\ 0, \text{基站}j\text{未被部署} \end{cases} \quad (17)$$

约束C1代表每个终端至少被一个基站覆盖，是网络的覆盖需求；C2代表所有基站在小区域 k 提供的容量要满足 k 区域的用户需求，是网络的容量需求；C3代表基站部署位置受到限制，只能被部署在研究区域之内。在此优化问题中，优化变量分别是 ε_j 、 L_j 与 B_j ，其中 L_j 与 B_j 是连续变量，而 ε_j 是离散变量，导致此优化问题是一个混合整数非线性规划问题，本文使用粒子群混合果蝇优化（fly optimization-particle swarm optimization, FO-PSO）算法来降低求解难度。

2.3 基于粒子群混合果蝇优化算法求解优化问题

粒子群算法具有优秀的全局搜索能力，使其非常适合应用于选址问题，但是其易陷入局部最优，可能导致站址规划结果不理想^[17]。使用文献[18]提出的FO-PSO算法，利用果蝇算法的更新公式增加粒子群算法的搜索多样性，从而避免陷入局部最优解。与使用单一更新公式的灰狼优化算法、可变长粒子群优化算法不同，FO-PSO算法的粒子种群更加丰富，具有求解精度高、求解复杂度较低、求解速度较快的优点。

算法中的粒子具有速度和位置2个关键属性，每个粒子在搜索空间中单独搜索个体最优解，并将个体最优解与其他粒子进行共享，找到最优的个体最优解作为整个粒子群的全局最优解。并且，每个粒子根据当前全局最优解更新自身速度与位置，具体更新数学式如下。

$$v_{ld}^{t+1} = \omega v_{ld}^t + c_1 r_1 (W_{ld}^{\text{opt}} - W_{ld}^t) + \quad (18)$$

$$c_2 r_2 (W_{ld}^{\text{opt}} - W_{ld}^t)$$

$$W_{ld}^t = W_{ld}^{t+1} + v_{ld}^{t+1} \quad (19)$$

$$WG_{ld}^{t+1} = r_1 W_{ld}^t + (1 - r_2) W_{gd}^{\text{opt}} \quad (20)$$

$$W_{ld}^{t+1} = WG_{ld}^{t+1} + R_d \times r_1 \quad (21)$$

其中， t 表示迭代次数， l 表示粒子的数量， d 表

示搜索空间的维度， v_{ld} 表示粒子 l 的速度， W_{ld} 表示粒子群算法中粒子 l 的位置， W_{ld}^{opt} 表示粒子 l 的当前个体最优位置， W_{gd}^{opt} 表示当前全局最优位置， WG_{ld}^{t+1} 表示果蝇算法得出的引导个体位置， W_{ld}^{t+1} 表示混合算法得出的最终位置结果， R_d 表示在 d 维的搜索半径， ω 表示保持当速度的惯性因子， r_1 、 r_2 表示0~1的随机数， c_1 、 c_2 表示学习因子，通常取值为2。

由式（20）可知，本文定义的引导个体位置 WG_{ld}^{t+1} 是 W_{ld}^t 与 W_{gd}^{opt} 的加权值。其综合了粒子群算法与果蝇算法的更新方式，在一定程度上可以降低单一更新模式在算法迭代后期导致的大量个体趋于相同，从而使得算法具有一定跳出局部最优解的能力，使种群更加丰富。

将搜索空间维度设定为基站数量的2倍，即每个粒子中包含所有基站的经纬度数据，初始的粒子表示如下。

$$W = (L_1, \dots, L_{N_{\text{BS}}}, B_1, \dots, B_{N_{\text{BS}}}) \quad (22)$$

为了判断粒子当前站址是否满足上文所述的覆盖约束与容量约束。将式（16）中的C1与C2约束转变为如下目标函数：

$$U_l^1 = \sum_{i=1}^M |\varepsilon_i^l - 1| \quad (23)$$

$$U_l^2 = \sum_{k=1}^L \left| M_{\text{cap}} \sum_{j=1}^{N_{\text{BS}}} \phi_{kj}^l - M_k \right| \quad (24)$$

其中，目标函数式（23）表示粒子 l 中被覆盖的用户数与总用户数的差值，目标函数式（24）表示粒子 l 中被服务的用户数与总用户数的差值。

本文设置覆盖阈值为 η ，容量阈值为 τ ，并适当放宽对覆盖与容量的要求。相应地，设置粒子 l 的个体最优目标值为 U_l^{opt} ，全局最优目标值为 U_g^{opt} 。

FO-PSO算法在迭代时，首先初始化粒子群，粒子数量为 l ，维度为 $2 \times N_{\text{BS}}$ 。在当前条件下通过粒子群算法求出最优站址后，将站点数进行递

减, 即 $N'_{BS} = N_{BS} - 1$, 再重新运行粒子群算法, 直至站点数不能满足目标函数式 (23) 或式 (24) 为止。将能够满足目标函数的最少站点数 $N_{BS}^{\min}$ 作为最终站点数, 在此情况下的粒子最优位置作为站址规划结果, 具体步骤如算法 1 所示。

算法 1 FO-PSO 算法

输入 基站数目 N_{BS} , 各区域用户分布

输出 最优基站数目 $N_{BS}^{\min}$ 与最优位置 W_{id}^{opt}

初始化粒子群 W , 设置最大迭代次数 $t_{\max}$

设置目标函数为 U^1

当 $t < t_{\max}$ 时

对于每一个粒子, 计算当前目标函数 U_l

若 $U_l < U_l^{\text{opt}}$

更新个体最优: $U_l^{\text{opt}} = U_l, W_l^{\text{opt}} = W_l$

记录全局最优: $U_g^{\text{opt}} = \min U_l^{\text{opt}}, W_g^{\text{opt}} = W_l^{\text{opt}}$

如式 (18) 到式 (21) 更新粒子速度与位置

若满足 $\min U_l \leq (1 - \eta)M$

修改 $U = U^2$

$t = t + 1$

若 W_g^{opt} 满足约束式 (12) 与约束式 (15)

将基站数目递减 $N'_{BS} = N_{BS} - 1$

重新执行上述步骤, 直至找到 $N_{BS}^{\min}$, 使其满足覆盖需求与容量需求

3 运维优化阶段

此阶段, 场景设立在已经建立完善可移动通信网络的大中型城市之内, 用户终端可将其接收信号强度指示 (received signal strength indication, RSSI) 上报至基站, 并从基站获取通信服务。终端用户具有动态性, 会导致网络覆盖率下降。此时便需要及时优化可移动基站站址, 恢复网络覆盖健康。为实现上述要求, 本阶段分为 2 个模块, 分别为基站站址优化模块与终端信号强度预测模块。基站站址优化模块采用 MADDPG 算法自动

判断当前网络状态, 智能体根据网络状态, 探索环境, 做出动作, 自动优化基站站址。终端信号强度预测模块将基站站址优化模块的输出, 即站址规划方案输入 LightGBM 算法, LightGBM 算法将根据训练好的模型计算当前网络覆盖率。若网络覆盖率达到设定好的阈值, 则认为当前建站方案效果良好; 否则, 将认为当前基站数量不满足当前网络流量要求, 将增加一个基站并重新在站址优化模块进行优化。

3.1 基站站址优化模块

基站站址优化模块采用 MADDPG 算法自动优化基站站址。此算法使用马尔可夫决策过程将站址优化问题转化为每一个迭代中的强化学习过程, 基于观测、动作与奖励空间的设计, 渐进地调整基站站址, 保持网络覆盖率。将可移动基站作为智能体, 基站站址优化模块设计如下。

(1) 观测空间。智能体只能观测到局部环境, 将可移动基站的观测信息作为智能体的观测空间, 可以特征化为: 可移动基站自身的经纬度信息, 以 (L_j, B_j) 表示; 可移动基站自身覆盖的终端经纬度信息, 以 I_j 表示; 可移动基站当前移动速度, 以 v_j 表示; 其他可移动基站的位置与所覆盖的终端位置信息, 由通信空间定义, 以 C_l 表示。观测空间 O_t 的数学表达式如下。

$$O_t = \{(L_j, B_j), I_j, v_j, C_l\} \quad (25)$$

(2) 通信空间。由于智能体只能观测到环境中的局部信息, 智能体之间需要通过通信的方式交换彼此需要的信息, 这些信息可以特征化为: 可移动基站自身的经纬度信息, 以 (L_j, B_j) 表示; 可移动基站自身覆盖的终端经纬度信息, 以 I_j 表示; 可移动基站自身做出的动作, A_t 以表示。通信空间可以帮助智能体得知其他智能体已经覆盖的区域, 从而避免智能体之间的过度资源竞争并协助智能体寻找自身最优位置, 从而加速算法收敛。 C_t 的数学表达如下。



$$C_t = \{(L_j, B_j), I_j, A_t\} \quad (26)$$

(3) 动作空间。考虑基站的移动性, 智能体的动作空间可以特征化为: 可移动基站在经度方向上的移动速度, 以 a_j^L 表示; 可移动基站在纬度方向上的移动速度, 以 a_j^B 表示。动作空间 A_t 的数学表达式如下:

$$A_t = \{a_j^L, a_j^B\} \quad (27)$$

(4) 奖励函数。奖励函数 r_t 由重叠覆盖惩罚值、基站越界惩罚值与相对距离奖励3部分构成, 即:

$$r_t = r_{\text{dis}} - P_{\text{ol}} - P_{\text{cd}} \quad (28)$$

$$r_{\text{dis}} = - \sum_i \min(d_{ij}) \quad (29)$$

其中, r_{dis} 表示奖励项, 定义为可移动基站与距离最近的终端簇之间的距离, 并且出于使奖励函数正向增长的习惯, 将距离取相反数作为奖励。在奖励函数的影响下, 距离终端 i 最近的基站会向此终端不断移动, 其他基站则不受影响。 p_{ol} 与 p_{cb} 分别是重叠覆盖与基站越界惩罚常数, 当因两基站之间相距过近而发生重叠覆盖与基站移出出研究区域时, 对智能体施加大小为 p_{ol} 与 p_{cb} 的惩罚值^[19]。

面对真实的蜂窝网络环境, 智能体从环境中获取上述局部观测值 o_t , 并依据策略函数 $\pi(a_t|o_t)$

输出动作 a_t 从而实现基站移动, 随后获取相应环境交互并计算奖励函数 r_t , 环境状态根据状态转移函数 $p_{\pi}(o_{t+1}|o_t, a_t)$ 转移至下一状态 s_{t+1} 。智能体输出动作的优劣程度由动作价值函数 $Q(o_t, a_t)$ 评判, 它表示智能体选择一个动作所能获得长期收益的均值, 收益较大的动作将被策略函数更加频繁地选取。当环境中存在多个智能体时, 策略函数、状态转移函数与动作价值函数受多个智能体的输出共同影响。本模块使用 MADDPG 算法, 智能体间相互通信获取其他智能体的观测空间与动作选择, 拟合全局状态价值函数 $Q(o_t^i, a_t^i, o_t^{-i}, a_t^{-i})$, 使智能体训练过程平稳, 其中 $-i$ 表示除当前智能体外的其他智能体^[20]。

MADDPG 智能体结构如图4所示。每个 MADDPG 智能体由4个神经网络所组成, 其中 Actor 网络与 Critic 网络均分为在线 (Online) 网络与目标 (Target) 2个版本。

其中, 在线 Actor 网络用于表征策略函数 $\pi(a_t|o_t)$, 神经网络参数是 θ_1 。当智能体获取局部观测状态 o_t 时, 在线 Actor 网络会输出动作分布的均值 $\mu_{\theta_1}(o_t)$ 与方差 $\sigma_{\theta_1}(o_t)$, 以输出动作选择策略。在线 Critic 网络用于表征动作价值函数 $Q(o_t, a_t)$, 神经网络参数是 θ_2 , 用于评估在线 Ac-




图4 MADDPG 智能体结构

tor 网络输出动作的优劣程度, 在线 Actor 网络会根据在线 Critic 网络的评估结果修改动作选择策略。目标网络是在线网络的副本, 目标 Actor 网络与目标 Critic 网络的网络参数分别为 θ_3 与 θ_4 。目标网络参数更新较为缓慢, 这能够提升训练过程的稳定性, 加快算法收敛速度。除此之外, 每个智能体还有一个经验回放池, 用于保存智能体在训练过程中产生的数据样本。训练时, 智能体从经验回放池中采样, 随机获取样本集用于计算目标梯度。具体而言, 在线 Actor 网络更新采用策略梯度更新:

$$\nabla_{\pi^j} \cong \frac{\sum_j \nabla_{\theta_1} \mu(o_j | \theta_1) \nabla_a(o_j, a_j | \theta_2)}{N} \quad (30)$$

在线 Critic 网络采用最小化损失函数来更新:

$$L = \frac{1}{N} \sum_j \left(r_j + \gamma \left(o_{j+1}, \pi_{\theta_1}^{o_{j+1}} \right) - Q(o_j, a_j | \theta_2) \right)^2 \quad (31)$$

其中, o_j 、 a_j 、 r_j 分别表示智能体 j 的观测、动作与奖励, N 表示智能体的数量, $\pi_{\theta_1}^{o_{j+1}}$ 表示在观测 o_{j+1} 状态下输出的动作。除此之外, 目标网络采用软更新机制, 具体如下:

$$\theta_3' \leftarrow \xi_1 \theta_3 + (1 - \xi_1) \theta_3' \quad (32)$$

$$\theta_4' \leftarrow \xi_2 \theta_4 + (1 - \xi_2) \theta_4' \quad (33)$$

其中, ξ_1 与 ξ_2 分别是目标 Actor 网络与目标 Critic 网络的学习率。智能体通过探索环境, 从环境中获取样本存放于经验回放池。在训练时, 从经验回放池中抽样获取批量样本, 根据式 (30) ~ 式 (33) 进行训练, 直至智能体达到最优动作输出策略。MADDPG 算法的具体步骤如算法 2 所示。

算法 2 MADDPG 算法

输入 基站位置信息, 终端位置信息

输出 基站更新位置信息

初始化每个智能体 Actor 网络与 Critic 网络参数

初始化经验回放池

For episode=1, For agent, do:

For $t=1$ do:

从环境中获取观测状态 o_t^j

将观测状态 o_t^j 交给 Actor 输出动作

a_t^j , 得到奖励 r_t^j , 进入下一状态 o_{t+1}^j

将 $(o_t^j, a_t^j, r_t^j, o_{t+1}^j)$ 存入经验回放池

与邻近智能体进行通信

从经验回放池中抽取样本, 根据式 (31)

更新在线 Critic 网络

根据式 (30) 更新在线 Actor 网络

根据式 (32) 更新目标 Critic 网络

根据式 (33) 更新目标 Actor 网络

End For

End For

3.2 终端信号强度预测模块

为了评估基站移动后的网络覆盖率, 终端信号强度预测模块采用 LightGBM 算法预测每一个终端的接收信号强度 I_{RSS}^i , 若优化后的基站站址仍不能满足网络覆盖需求, 则在通信网络中新增可移动基站, 重新进行站址规划。

LightGBM 算法属于监督学习算法, 需要大量数据训练预测模型。为了准确预测终端接收信号强度, 需要尽可能地考虑影响因素。首先, 由于电磁波的传播特性, 基站与终端之间的距离最为重要。其次, 在城市区域中, 信号会被巨大的建筑物遮挡, 产生反射与衍射现象, 因此基站与终端所处的地理位置也是至关重要的因素。最后, 基站的一些配置参数也是重要影响因素, 如基站高度、基站发射功率、基站发射频率、天线下倾角与天线高度等。

3.2.1 数据预处理

从江苏省运营商真实运行的蜂窝网络中采集数据, 主要包含基站经纬度、高度、发射功率、天线高度与终端经纬度等参数, 约 2 万条数据, 形成数据集。数据集可分为用于训练预测模型的训练集与用于评估模型准确性的测试集。在模型



训练之前, 首先需要对数据集进行预处理, 包括数据清洗、特征选择与数据集划分。数据清洗工作将与接收信号强度不相关的数据删除, 并且处理缺省的样本值; 特征选择工作选取剩下的数据作为新的特征。最终选取的特征为:

$$[L_{BS}, B_{BS}, h_{BS}, P_{BS}, L_{UE}, B_{UE}, d_{ij}] \quad (34)$$

其中, L_{BS} 代表基站经度, B_{BS} 代表基站纬度, h_{BS} 代表基站高度, P_{BS} 代表基站发射功率, L_{UE} 代表终端经度, B_{UE} 代表终端纬度, d_{ij} 代表基站与终端之间的距离。

对于每一个终端 i , 数据集都记录了它的接收信号强度 I_{RSS}^i , 并将此值作为监督学习的标签, 与上述特征一同输入 LightGBM 算法。

3.2.2 LightGBM 预测模型训练

LightGBM 算法是实现梯度提升决策树 (gradient boosting decision tree, GBDT) 的一种高效框架。GBDT 利用了集成学习思想, 将多个弱分类器进行迭代训练以得到最优模型。LightGBM 对 GBDT 做出了许多改进, 并且支持并行训练, 拥有训练速度快、内存消耗少、预测准确率高和可处理海量数据等优点。

在样本采样方面, LightGBM 算法采用了直方图算法, 把连续的特征值离散化为 K 个整数, 同时构建一个宽度为 K 的直方图。在遍历数据时, 根据离散化后的值作为索引在直方图中累计统计量。在遍历完数据后, 根据直方图的离散值, 遍历寻找最优分割点。

在减小开销方面, LightGBM 算法采用了叶子生长策略, 该策略每次从当前所有叶子中, 寻找分裂增益最大的一个叶子。对比按层生长策略, 叶子生长策略可以降低误差, 获得更大的精度。

从减少样本数方面, LightGBM 算法采用了单边梯度采样算法, 该算法在对数据进行采样时只保留梯度较大的数据, 丢弃一些对计算信息增

益作用小的样本^[21]。

终端信号强度预测模块在训练时将采集的网络数据集划分为训练集与测试集, 训练好的模型在测试集的数据下若达到 95% 的正确率, 则认为模型较为准确, 将用于信号强度预测。终端信号强度预测模块在使用时, 将基站与终端的实时数据作为输入, 模块将输出终端信号强度数值。具体如算法 3 所示。

算法 3 LightGBM 算法

输入 训练集样本, 站址规划结果

输出 终端信号强度

初始化学习参数, 初始化叶子节点与 Hessian 矩阵

加载数据集的特征与标签, 创建初始叶子节点

For episode:

计算所有样本的梯度: $G = -\sum_{i=1}^N y_i \log(\hat{y}_i)$

计算 Hessian 矩阵: $H = \frac{\partial^2 G}{\partial \theta_i \partial \theta_j}$

For Leaves:

计算当前叶子节点增益:

$$\text{Gain} = \frac{1}{2} \left[\frac{G^2}{H + \lambda} - \frac{G_l^2}{H_l + \lambda} - \frac{G_r^2}{H_r + \lambda} \right]$$

寻找最佳分裂点

若最佳分裂点增益大于零, 更新叶子节点 Hessian 矩阵

$$\text{更新叶子节点分数 } \text{Score}(\omega) = -\frac{G}{H + \lambda}$$

For all samples:

根据特征找到叶子节点

返回叶子节点分数作为预测值

在算法 3 中, y 是真实标签, y_i 是预测标签, θ_i 与 θ_j 是算法中的参数, G_l 、 G_r 与 H_l 、 H_r 分别代表左子节点与右子节点的梯度与 Hessian 矩阵和, λ 是超参数。

4 仿真分析

通过仿真实验评估所提出的基站规划优化方法, 设置研究区域在纬度 $22.65^{\circ} \sim 22.75^{\circ}$, 经度 $113.75^{\circ} \sim 113.80^{\circ}$, 仿真实验分为初始部署阶段与运维优化阶段两个方面。

4.1 初始部署阶段仿真分析

基站初始部署阶段使用 MATLAB R2020a 仿真平台构建 FO-PSO 算法进行实验, 实验参数选取见表 1。

表 1 实验参数选取

实验参数	取值
平均街道宽度 w_{str}	30 m
平均建筑高度 h_{build}	25 m
发射台天线绝对高度 h_{BS}	25 m
天线绝对高度 h_{AP}	1.5 m
基站发射频率 f_c	2.6 GHz
基站发射功率 P_{BS}	30 dBm
噪声功率谱密度 σ^2	-105 dBm
单基站峰值速率 T_{BS}	100 Gbit/s
用户体验速率 T_{AP}	1 Gbit/s
信干噪比阈值 R_{SIN}^0	-0.5 dB

根据文献[22]的室外传输模型参数选择, 本文将无线信号发射频率设置为 2.6 GHz, 基站海拔高度设置为 25 m, 终端天线绝对高度设置为 1.5 m。利用 3GPP 36.873 UMa 传输模型计算得到基站覆盖半径为 1.21 km。根据文献中链路预算, 将最大容许下行链路损耗 γ_{Lp} 设置为 143.7 dB。在上述研究区域内按泊松分布共生成终端用户 668 个, 经过网络规模估算, 为满足覆盖约束需要 11 个基站, 为满足容量约束需要 9 个基站, 综合得出网络规模估算结果为 11 个基站。在此基础之上, 使用 FO-PSO 算法不断减少基站数目, 并求解基站最优站址。设置粒子个数为 50, 最大迭代次数设置为 100, 基站初始部署阶段不同基站数目下覆盖率与服务率对比如图 5 所示。




图5 不同基站数目下覆盖率与服务率对比

覆盖率代表处于基站覆盖范围内的终端占有所有终端的比例, 服务率指被分配到通信资源的终端占总终端数的比例。从图5可以看出, 基站个数为11时, 网络覆盖率可达到93.13%, 服务率达到99.50%; 当基站个数逐渐减少时, 网络服务率略有下降, 而覆盖率有所上升, 这是因为随基站数目减少, 基站所能提供的通信资源减少, 基站之间的干扰也逐步降低, 导致终端 SINR 有所提升。当基站数量减少至8时, 网络覆盖率达到99.25%, 继续减少基站, 开始出现覆盖空洞, 网络覆盖率开始下降。本节目标是在网络覆盖率与服务率均达到95%的情况下, 尽量减少基站数量以节约建站成本。由图5可知, 基站数量为7时, 最符合当前网络需求。

FO-PSO 算法计算得出的初始部署阶段基站站址规划结果如图6所示。




图6 初始部署阶段站址规划结果



在图6中,灰色圆点代表终端,在每个区域内,终端服从泊松分布,黑色三角代表基站最优部署位置,此时网络覆盖率达到97.01%。

为了验证FO-PSO算法应用在初始部署阶段的优势,将其与AVLPSO^[5]和原始PSO算法进行对比。在初始部署阶段,不同粒子群优化算法的规划结果对比如图7所示。从总体趋势来看,FO-PSO算法的覆盖率与服务率在相同基站数目时均高于2种对比算法,这是由于FO-PSO在传统PSO算法的基础上改善了参数更新方式,改善了PSO算法易陷入局部最优的缺点,使规划的站址更接近最优站址。




图7 不同粒子群算法规划结果对比


4.2 运维优化阶段仿真分析

为进一步对本文提出的基站运维优化方法进行仿真验证,经过对数据集规模的考虑,本文设置MADDPG中Actor与Critic网络均采用神经元数目为64的循环神经网络(recurrent neural network, RNN),学习率设置为0.001,折扣因子设置为0.95,神经元数量为64,批量大小为80,1024批同时训练。在Python3.9平台上,利用Tensorflow工具包实现MARL算法,计算机环境为Windows 11、GTX4060 GPU。


在运维优化阶段,假设有100个终端用户位置发生随机变化,导致网络覆盖率下降。实验模

拟终端随机运动的2种情况,即场景一与场景二。场景一中,终端距离基站初始位置较近,利用此场景评估本文所提出算法的覆盖恢复能力。场景二中,终端距离初始基站比较远,用于对比MARL算法的适用性。场景一中,终端移动过后,网络覆盖率降至78%;场景二中,网络覆盖率降至62%。

分别使用本文所提运维优化算法与传统提升回归树(boosted regression tree, BRT)联合k-means算法^[9]对2个场景中的基站站址进行运维优化。其中,提升回归树算法的损失函数拟合用的是平方损失,而本文选取的LightGBM算法损失函数拟合用的是负梯度。场景一、场景二的优化结果对比如图8、图9所示。其中,黑色三角代表基站位置,灰度圆点代表终端位置,圆点颜色越接近黑色代表终端RSSI值良好,反之则欠佳。




(a) 场景一站址规划




(b) 场景一对比算法站址规划

图8 场景一基站优化结果对比



(a) 场景二基站规划



(b) 场景二对比算法站址规划

图9 场景二基站优化结果对比

本文提出的算法可将覆盖率恢复至 99%，而 k -means 算法只能将覆盖率恢复至 92%。这是由于 k -means 算法基于最小距离将终端分簇，基站只能部署在终端簇中心，导致终端簇边缘地区的覆盖率不佳。本文提出的算法通过设计合理的奖励与通信空间，自动协调基站之间的位置，基站之间相互配合覆盖彼此的簇边缘地区，可以更好地解决网络弱覆盖问题。

场景二中，本文所提算法将覆盖率恢复至 93%，而 k -means 算法只能将覆盖率恢复至 82%，远远低于预设阈值。这是由于 k -means 算法对基站初始位置要求极为苛刻，若某一基站远离所有终端，则此基站将不会受到算法的调控，导致网络覆盖率大幅度下降。而本文提出的算法可以合理地设置奖励函数，使基站向终端位置靠拢，无须对基站初始位置进行严格要求，由此得出所提

算法具有良好的适用范围。

根据图 9 (a)，所提算法的网络覆盖率为 93%，并未达到预设阈值 95%。在此情况下，模块将在网络中添加一个可移动基站，并重新调用站址优化模块进行运维优化，通过增加基站数量的方式增大网络覆盖面积，进而提高网络覆盖率。最终，增加基站后的站址优化结果如图 10 所示，增加基站后的收敛曲线如图 11 所示。




图10 增加基站后站址优化结果




图11 增加基站后收敛曲线

由图 10 与图 11 可知，本文所提算法在新增基站后仍然可以在 90 000 轮训练之内达到收敛，并且可将覆盖率恢复至 99%，达到了预设阈值，证明了算法在极端情况下仍有快速覆盖恢复能力。

综上所述，本文所提算法相较于传统算法在覆盖率恢复能力与场景适用性上具有优势，并且可以增减基站以进一步优化网络覆盖率。运维优化阶段的仿真结果总结见表 2。



表2 运维优化阶段仿真结果总结

算法	场景一 (比较覆盖恢复)	场景二 (比较适用性)
MADDPG+LightGBM	覆盖率恢复 21%	覆盖率恢复 37%
BRT+k-means	覆盖率恢复 14%	有基站无法调控

5 结束语

本文提出了大中型城市可移动基站初始部署与运维优化的联合方法。该方法分为2个阶段：初始部署阶段，考虑了终端用户的覆盖需求与容量需求，力求在建立最少基站的情况下，通过FO-PSO算法计算最优基站站址，保证网络服务质量；运维优化阶段，考虑了终端用户移动之后，网络覆盖率降低的情况，通过MADDPG算法联合LightGBM算法进行覆盖率恢复。仿真分析结果表明，本文所设计的初始部署阶段方法可以准确地找到可移动基站的最优站址，最大限度地保证了用户服务质量。本文所设计的运维优化方法，可以最大限度地进行覆盖率恢复，并且在很多场景下均具备一定的适用性。

本次研究为在大中型城市部署可移动基站提供了一种解决思路，但仍存在一些局限性。未来的工作可以从以下两个方面入手。（1）运维优化阶段需要历史网络数据用于模型训练。在历史数据缺失的城市，终端信号强度预测的准确性会受到影响，而通过迁移学习等方法，这一问题可以被有效解决。（2）本文仅针对基站数量、基站站址这2个关键参数进行了优化，基站的发射功率、发射频率与方位角等其他参数也是影响网络覆盖状况的关键因素，这需要一套精心设计的AI算法，联合协调优化所有基站配置参数加以解决。

参考文献：


- [1] KARVOUNAS D, VLACHEAS P, GEORGAKOPOULOS A, et al. An opportunistic approach for coverage and capacity optimization in Self-Organizing Networks[C]//Proceedings of the 2013 Future Network & Mobile Summit. Piscataway: IEEE Press, 2013: 1-10.
- [2] VATSH I, GUPTA V, BHATTACHARYYA B. Optimizing base

station deployment for LTE using metaheuristic algorithms[C]//Proceedings of the 2019 International Conference on Vision Towards Emerging Trends in Communication and Networking (ViTECoN). Piscataway: IEEE Press, 2019: 1-5.

- [3] SHI G L, QIU D X, HU Q L. Three-dimensional position deployment of UAV base stations based on improved grey wolf optimization algorithm[C]//Proceedings of the 2024 IEEE 4th International Conference on Electronic Technology, Communication and Information (ICETCI). Piscataway: IEEE Press, 2024: 997-1002.
- [4] 马力鹏, 冀涵叶. 改进遗传算法在站址与小区工参联合优化中的应用[J]. 移动通信, 2023, 47(5): 76-82.
MA L P, JI H Y. Application of improved genetic algorithm in joint optimization of station location and community engineering parameters[J]. Mobile Communications, 2023, 47(5): 76-82.
- [5] WANG Y, ZHU X R. A novel network planning algorithm of three-dimensional dense networks based on adaptive variable-length particle swarm optimization[J]. IEEE Access, 2019, 7: 45940-45950.
- [6] HANH N T, BINH H T T, TRUONG V Q, et al. Node placement optimization under Q-Coverage and Q-Connectivity constraints in wireless sensor networks[J]. Journal of Network and Computer Applications, 2023, 212: 103578.
- [7] YU G J, YEH K Y. A k-means based small cell deployment algorithm for wireless access networks[C]//Proceedings of the 2016 International Conference on Networking and Network Applications (NaNA). Piscataway: IEEE Press, 2016: 393-398.
- [8] GHAZZAI H, YAACOU B E, ALOUINI M S, et al. Optimized LTE cell planning with varying spatial and temporal user densities[J]. IEEE Transactions on Vehicular Technology, 2016, 65(3): 1575-1589.
- [9] 朱晓荣, 沈瑶. 基于数据挖掘的RPMA低功耗广域网网络规划方法[J]. 通信学报, 2019, 40(3): 28-35.
ZHU X R, SHEN Y. RPMA low-power wide-area network planning method based on data mining[J]. Journal on Communications, 2019, 40(3): 28-35.
- [10] LU F X, MI Z C, ZHAO N, et al. 3D deployment of dynamic UAV base station based on mobile users[C]//Proceedings of the 2021 International Conference on Advanced Computing and Endogenous Security. Piscataway: IEEE Press, 2022: 1-5.
- [11] KIM T Y, LEE J, KIM J H. Deep reinforcement learning-based full-duplex communication UAV base station trajectory optimization in disaster environments[C]//Proceedings of the 2023 VTS Asia Pacific Wireless Communications Symposium (APWCS). Piscataway: IEEE Press, 2023: 1-5.
- [12] LEE H, EOM C, LEE C. QoS-Aware UAV-BS deployment optimization based on reinforcement Learning[C]//Proceedings of the 2023 International Conference on Electronics, Information, and Communication (ICEIC). Piscataway: IEEE Press, 2023: 1-4.

- [13] 张尚伟,和思梦.空地网络资源分配与无人机基站动态部署算法[J].西安交通大学学报,2024,58(3):172-182.
ZHANG S W, HE S M. Resource allocation of air-ground network and dynamic deployment algorithm of UAV base station[J]. Journal of Xi'an Jiaotong University, 2024, 58(3): 172-182.
- [14] 黄标,彭木根.无线网络规划与优化导论[M].北京:北京邮电大学出版社,2011.
HUANG B, PENG M G. Introduction to wireless network planning and optimization[M]. Beijing: Beijing University of Posts and Telecommunications Press, 2011.
- [15] 杨燕玲. LTE移动网络规划与优化[M].北京:北京邮电大学出版社,2018.
YANG Y L. LTE mobile network planning and optimization[M]. Beijing: Beijing University of Posts and Telecommunications Press, 2018.
- [16] 杨光,陈锦浩. 5G移动通信系统的传播模型研究[J]. 移动通信, 2018, 42(10): 28-33.
YANG G, CHEN J H. Research on propagation model for 5G mobile communication systems[J]. Mobile Communications, 2018, 42(10): 28-33.
- [17] 杨英杰. 粒子群算法及其应用研究[M].北京:北京理工大学出版社,2017.
YANG Y J. Particle swarm optimization and its applications[M]. Beijing: Beijing Institute of Technology Press, 2017.
- [18] 刘娟,杨春花. 粒子群果蝇混合改进算法在基站选址优化问题中的应用[J]. 计算机与数字工程, 2021, 49(7): 1341-1345, 1356.
LIU J, YANG C H. Application of improved hybrid algorithm based on PSO & FOA in base station location planning problem[J]. Computer & Digital Engineering, 2021, 49(7): 1341-1345, 1356.
- [19] 许文俊,吴思雷,王凤玉,等. 基于多智能体强化学习的大规模灾后用户分布式覆盖优化[J]. 通信学报, 2022, 43(8): 1-16.
XU W J, WU S L, WANG F Y, et al. Large-scale post-disaster user distributed coverage optimization based on multi-agent reinforcement learning[J]. Journal on Communications, 2022, 43(8): 1-16.
- [20] 吴官翰,贾维敏,赵建伟,等. 基于多智能体强化学习的混合博弈模式下多无人机辅助通信系统设计[J]. 电子与信息学报, 2022, 44(3): 940-950.
WU G H, JIA W M, ZHAO J W, et al. MARL-based design of multi-unmanned aerial vehicle assisted communication system with hybrid gaming mode[J]. Journal of Electronics & Information Technology, 2022, 44(3): 940-950.
- [21] 张硕伟,裴明丽,高有利,等. 基于LightGBM算法的MR网络信号预测[J]. 邮电设计技术, 2020(10): 21-25.
ZHANG S W, PEI M L, GAO Y L, et al. MR network signal prediction based on LightGBM algorithm[J]. Designing Techniques of Posts and Telecommunications, 2020(10): 21-25.
- [22] 袁周阳,赵伟康,吴迪. 基于UMa和RMa传播模型的5G覆盖性能研究[J]. 移动通信, 2020, 44(10): 1-6.
YUAN Z Y, ZHAO W K, WU D. Research on 5G coverage performance based on UMa and RMa propagation models[J]. Mobile Communications, 2020, 44(10): 1-6.

[作者简介]



赵欣然(1999-),男,南京邮电大学通信与信息工程学院硕士生,主要研究方向为无线网络规划优化、网络故障诊断等。



陈美娟(1971-),女,博士,南京邮电大学通信与信息工程学院副教授,主要研究方向为移动通信网络资源分配优化算法。



袁志伟(2000-),男,南京邮电大学通信与信息工程学院硕士生,主要研究方向为联邦学习、区块链等。



朱晓荣(1977-),女,博士,南京邮电大学通信与信息工程学院教授、博士生导师,主要研究方向为5G/6G网络、智能物联网、网络大数据、区块链、群体智能等。