

无人机辅助的6G空地一体化网络多维度资源动态分配算法研究

管明祥¹, 吴舟², 高宽栋¹, 戴一珏¹, 王乐¹, 崔英杰¹, 唐辉¹

(1. 深圳信息职业技术学院信息与通信学院, 广东 深圳 518172; 2. 深圳信息职业技术学院中德机器人学院, 广东 深圳 518172)

摘要: 针对6G网络数据量大、深度学习模型可能难以捕捉数据中复杂的时空特征、6G信号特征快速变化导致的深度学习模型预测滞后等问题, 提出了一种基于变分模态分解-长短期记忆网络-深度Q网络(VMD-LSTM-DQN)组合模型的无人机辅助6G空地一体化网络多维度资源动态分配算法。通过联合自适应信号数据分解、长短期记忆网络和深度强化学习的算法组合模型迭代与优化, 实现了对频谱、时间和空间资源的高效分配, 以最大化无人机辅助6G空地一体化网络的整体性能, 同时确保地面用户的服务质量不受影响。仿真结果表明, 所提算法在网络吞吐量、公平性和无人机网络能效等方面具有较好的性能。

关键词: 变分模态分解; 长短期记忆网络; 深度学习; 空地一体化网络

中图分类号: TP18; TN929.5

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2025199

Research on multi-dimensional resource dynamic allocation algorithm for UAV assisted 6G air-ground integrated network

GUAN Mingxiang¹, WU Zhou², GAO Kuandong¹, DAI Yijue¹, WANG Le¹, CUI Yingjie¹, TANG Hui¹

1. School of Information and Communication, Shenzhen University of Information Technology, Shenzhen 518172, China

2. School of Sino-German Robotics, Shenzhen University of Information Technology, Shenzhen 518172, China

Abstract: Aiming at the problems of large data volume in 6G network, difficulty in capturing complex spatiotemporal features in data by deep learning models, and lagging prediction of deep learning models caused by rapid changes in 6G signal features, a UAV assisted dynamic resource allocation algorithm for 6G air-ground integrated network based on VMD-LSTM-DQN combination model was proposed. Through iterative optimization of the algorithm combination model of joint adaptive signal data decomposition, long short-term memory network, and deep reinforcement learning, efficient allocation of spectrum, time, and spatial resources was achieved to maximize the overall performance of UAV assisted 6G air-ground integrated network while ensuring that the service quality of ground users was not affected. The simulation results show that the proposed algorithm has good performance in network throughput, fairness, and drone network energy efficiency.

Keywords: variational mode decomposition, long short-term memory network, deep learning, air-ground integrated network

收稿日期: 2025-09-09; 修回日期: 2025-11-04

通信作者: 吴舟, 66827983@qq.com

基金项目: 广东省自然科学基金资助项目(重点项目)(No.2022B1515120002); 深圳市创新创业计划科技重大专项基金资助项目(No.KJZD20240903103300002); 深圳市科技创新局基金资助项目(No.KCXFZ20240903094011015); 学校重点研究领域支持基金资助项目(No.SZII2024KJ044)

Foundation Items: The Guangdong Natural Science Foundation (Key Project) (No.2022B1515120002), The Shenzhen Innovation and Entrepreneurship Plan Major Science and Technology Special Project (No.KJZD20240903103300002), The Project of Shenzhen Science and Technology Innovation Committee (No.KCXFZ20240903094011015), The Key Research Fields Support Scientific Research Projects (Science and Technology) of SUIIT (No.SZII2024KJ044)

0 引言

6G 系统有望推动沉浸式扩展现实、数字孪生、智能交通等关键应用的发展,进一步实现物理世界与数字世界跨时区和地理区域的深度融合^[1]。要实现这一愿景,6G 系统不仅需要满足峰值传输速率大于 100 Gbit/s、传输时延 0.1 ms 和可靠性大于 99.999 99% 的要求,而且还需要将 5G 系统的设备连接密度和覆盖能力提高 10 倍以上。另外,随着 6G 业务场景的多元化发展,用户终端不再局限于城镇等无线覆盖成熟区域,而是迅速向山区、海洋、天空等非成熟覆盖区域延伸。因此,快速增长的性能需求和不断扩展的业务场景迫使 6G 系统从传统基于表面的覆盖发展到三维覆盖。基于这一目标,6G 系统将利用各种机型与传统地面网络集成,进一步构建空地一体化网络。

空地综合网络是在地面网络的基础上扩展到空中网络领域,空中基站辅助地面基站为各类用户提供必要的服务和信息支持^[2-3]。空地综合网络利用无线通信技术实现地面网络和空中网络的互操作,突破三者之间的业务承载模式,通过一个共同的平台实现各种信息的覆盖。空中网络是由飞艇、热气球、无人机(UAV, unmanned aerial vehicle)编队、侦察机等组成的空中组件。地面网络包括控制中心、应用中心、数据中心和地面信息网络基础设施,如蜂窝网络、移动通信网络、移动互联网和云数据中心。空地一体化网络虽然存在节点设备多、资源实体复杂和单网异构问题,但如果能将两大网络有效结合,将更充分地利用网络的综合效能,更好地处理未来通信中复杂多样的任务,这对于加强信息化建设,扩大国家利益具有重要意义。

空地一体化网络是由具有不同移动特性、资源特性和业务特性的各类设备组成的多维异构网络,其网络规模远大于传统地面网络,且结构更复杂,动态性更高^[4-5]。这使空地一体化网络中的无线资源管理模块面临着难以捕获和预测业务、资源变化特征等挑战。在传统的移动通信系统中,有必要摆脱基于模型的设计理念,转向数据驱动的自动配置方法,以提高系统整体网络性能。

近年来,随着机器学习(ML, machine learning)和人工智能(AI, artificial intelligence)技术的快速发展,网络资源管理逐渐转向智能化,尤其是分布式智能,这将成为未来大规模异构网络性能

优化的重点^[6-8]。北美 NextG 联盟的 6G 技术报告^[9]也提到,在未来 6G 系统中,将 AI 能力汇聚到用户终端和边缘设施的分布式 AI 能力部署方案将取代核心网端的单一 AI 能力部署方案。虽然这些体系结构为 ML/AI 技术在空地综合网络中的应用提供了指导思想,但在空地综合网络智能方案的实际部署过程中,各种飞行节点与地面节点在运动特性、可用资源、计算能力等方面存在着显著差异。因此,很难通过调动不同类型节点的 AI 能力来充分优化空地综合网络的全局性能^[10]。因此,为了推进空地综合网络的智能化进程,如何使空地综合网络中不同类型的节点充分利用本地 AI 能力,进一步协作构建灵活高效的无线资源分配机制成为一个亟待解决的问题。

传统的无线资源管理模块主要着眼于根据网络中不断变化的用户业务需求灵活配置空间、时间和频率资源,以最高的能量利用效率和最低的信令开销避免网络拥塞问题。然而,在空地一体化网络中,各种飞行节点的混合移动特征不仅加剧了用户业务需求的变化,而且使可用的网络资源和信道条件具有高度动态性。在这种情况下,传统的无线资源管理模块需要利用不同飞行基站的移动特性和业务特性,使其成为新的资源维度,进而实现对用户的动态多维资源分配,从而优化网络的长期性能。

文献[11]考虑了用户服务优先级,并利用遗传算法最大化用户和速率,同时有效避免了终端移动性导致的切换。文献[12]使用粒子群算法在非地面网络切换时延约束下最大化用户传输速率和基站负载均衡。文献[13]在优化目标中进一步考虑了资源利用率和用户覆盖时间,提出了一种适用于动态环境的序贯决策方案。文献[14]主要研究低轨卫星星座中星际链路的信道分配问题,该方案引入中央控制节点计算卫星轨道参数,利用匹配算法将信道资源分配给不同的星际链路,达到系统整体速率最大化的目标。文献[15]提出了一种基于软件定义网络的集中式资源分配机制。文献[16]引入 Q 学习算法,建立了智能信道容量分配算法,以满足不同业务优先级用户的带宽需求。此外,为了实现高度灵活的频谱资源分配架构,文献[17]进一步结合软件定义网络和 AI 技术提出了一种分层方案,该方案基于网络切片进行细粒度带宽配置,能够满足用户长期业务需求,并应对突发业务需求。文献[18]将智能超表面安装在无人

机上, 实现全角度反射, 扩大无人机的覆盖范围。该方法利用深度强化学习算法学习无人机与用户之间高维信道状态的变化规律, 采用优先级经验回放机制训练深度 Q 网络 (DQN, deep Q-network) 获得智能波束形成策略。文献[19]利用聚类和深度神经网络 (DNN, deep neural network) 等 ML/AI 技术, 设计了一种基于角度域信息的快速模拟波束形成架构, 优化了毫米波非正交多址接入波束形成矢量, 与传统方法相比, 主从式无人机编队方法进一步增强了无人机的覆盖能力, 在动态环境下具有较高的鲁棒性。上述文献在融合网络的用户关联与资源分配问题上做出了相应研究, 并取得了一定的前瞻性与工程实际意义, 但是在能耗控制、算法参数自适应、实时性以及计算复杂度等方面仍有改进空间。基于这些问题, 本文提出了一种基于变分模态分解-长短期记忆网络-深度 Q 网络 (VMD-LSTM-DQN) 组合模型的无人机辅助 6G 空地一体化网络多维度资源动态分配算法。本文的主要工作和贡献如下。

1) 针对 6G 空地一体化网络数据量大的问题, 使用变分模态分解 (VMD, variational mode decomposition) 技术, 将接收到的 6G 网络毫米波信号分解为若干个不同频率范围的本征模态函数 (IMF, intrinsic mode function) 子信号 (模态), 使每个模态信号的带宽最小化, 将每个 IMF 数据根据频率由高到低排列, 对排列后的 IMF 数据进行筛选和融合, 降低了后续长短期记忆网络 (LSTM, long short-term memory network) 模型训练的难度, 减轻了无人机的边缘计算负担, 减缓了无人机电源的消耗。

2) 针对深度学习模型可能难以捕捉数据中复杂的时空特征的问题, 研究并搭建了 LSTM 模型, 利用 VMD 技术分解后的 IMF 数据、空中基站的发射功率以及高度等参数一起作为训练数据去训练 LSTM 模型, 构建 6G 空地一体化网络资源预测模型, 对网络资源进行预测分配, 然后根据预测结果调整空中基站的位置以满足网络容量最大化的需求。

3) 针对 6G 信号特征快速变化导致的深度学习模型预测滞后问题, 搭建深度 Q 网络强化学习模型, 利用深度强化学习的实时在线学习能力, 实时根据设备位置、业务需求变化以及各种信道环境参数的变化不断优化调整深度学习的决策过程, 实时动态调整网络资源的分配策略以及空中基站的位置, 满足实时性要求。

1 系统模型

首先构建一个高精度的无人机辅助地面无线网络模型, 该模型将综合考虑无人机的位置、速度、通信需求以及地面用户的分布和服务质量要求。

无人机辅助地面无线网络模型与地面通信的传播方式不同, 这主要取决于传播环境和传输角度。空地信道链路可以通过概率路径损耗模型进行建模, 该模型包括视距 (LOS, line of sight) 和非视距 (NLOS, none line of sight) 2 种路径, 如图 1 所示。




图1 无人机辅助地面无线网络模型

从 UAV n 到设备 m 的 LOS 和 NLOS 路径损耗分别表示为

$$L_{n,m}^{\text{LOS}} = 20\lg\left(\frac{4\pi f_c d_{n,m}}{c}\right) + \mu^{\text{LOS}} \quad (1)$$

$$L_{n,m}^{\text{NLOS}} = 20\lg\left(\frac{4\pi f_c d_{n,m}}{c}\right) + \mu^{\text{NLOS}} \quad (2)$$

其中, f_c 和 c 分别表示载波频率和光速, $d_{n,m}$ 表示 UAV n 与第 m 个设备之间的距离, μ^{LOS} 和 μ^{NLOS} 分别表示 LOS 和 NLOS 路径的额外损耗。

从第 n 个 UAV 到第 m 个设备的 LOS 链路概率定义为

$$\Gamma_{n,m}^{\text{LOS}} = \frac{1}{1 + v_1 \exp(-v_2(\theta_{n,m} - v_1))} \quad (3)$$

其中, v_1 和 v_2 是依赖于 UAV 网络的常数参数, $\theta_{n,m}$ 是从无人机 n 到设备 m 的传输角度。相应地, NLOS 链路概率为 $\Gamma_{n,m}^{\text{NLOS}} = 1 - \Gamma_{n,m}^{\text{LOS}}$ 。

从无人机 n 到设备 m 的概率路径损耗可以表示为

$$L_{n,m} = L_{n,m}^{\text{LOS}} \Gamma_{n,m}^{\text{LOS}} + L_{n,m}^{\text{NLOS}} \Gamma_{n,m}^{\text{NLOS}} \quad (4)$$

那么第 n 个无人机接收到的 6G 信号 \mathbf{Y}_n 可以表示为

$$\mathbf{Y}_n = \sum_{m=1}^M \sqrt{p_{n,m}} L_{n,m} x_m + \underbrace{I_{\text{intra}} + I_{\text{inter}}}_{\text{干扰项}} + \sigma_m^2 \quad (5)$$

其中, $p_{n,m}$ 表示第 n 个无人机到第 m 个设备的发射功率, x_m 表示第 m 个设备的发射信号, σ_m^2 表示第 m 个设备的噪声, $L_{n,m}$ 表示式(4)所示的从无人机 n 到设备 m 的概率路径损耗。 I_{intra} 表示子信道同频干扰, 可以表示为

$$I_{\text{intra}} = \sum_{j=1, j \neq m}^M \sqrt{p_{n,j}} L_{n,j} x_j \quad (6)$$

其中, $p_{n,j}$ 表示第 n 个无人机到第 j 个设备的发射功率, x_j 表示第 j 个设备的发射信号, $L_{n,j}$ 表示式(4)所示的从无人机 n 到设备 j 的概率路径损耗。 I_{inter} 表示无人机交叉干扰, 可以表示为

$$I_{\text{inter}} = \sum_{i=1, i \neq n}^N p_n L_{n,i} \quad (7)$$

其中, p_n 为无人机发射功率, $L_{n,i}$ 为无人机 n 到设备 i 的概率路径损耗。

本文算法所使用的系统参数如表 1 所示。

表 1 系统参数

参数	含义
μ	Adam 优化器的学习率, 控制参数更新步长
γ	折扣因子
D	经验池容量
ζ	深度 Q 网络模型探索率
q_1, q_2, q_3	深度 Q 网络模型奖励函数各因素权重系数
N	无人机数量
l_i	深度 Q 网络模型第 i 个无人机带宽分配权重
m_i	深度 Q 网络模型第 i 个无人机发射功率权重
θ_1, θ_2	全连接层参数集合
β_1, β_2	Adam 优化器的指数衰减率
M	地面用户设备数量
σ_m	第 m 个用户设备的噪声
ν_1, ν_2	无人机到设备的 LOS 链路概率常数参数
$p_{n,m}$	第 n 个无人机到第 m 个设备的发射功率
ω_k	6G 混合信号第 k 个信号的中心频率
ω_{\max}	6G 混合信号最大中心频率
u_k	第 k 个模态分量信号
λ	拉格朗日乘数
α	拉格朗日惩罚因子
K	VMD 算法模态数
ε	拉格朗日收敛阈值
f_s	6G 系统采样频率
τ	拉格朗日乘子更新步长
$\varsigma_1, \varsigma_2, \varsigma_3$	无人机分配带宽、发射功率和高度均方误差权值

2 算法设计

2.1 自适应信号分解模型

未来新兴的 6G 网络将采用毫米波, 将工作在 D 频段 (110~170 GHz) 和 H 频段 (220~330 GHz)。现有的一些机器学习模型在 6G 网络进行预测时, 都是直接将接收到的 6G 混合信号作为训练数据去训练机器学习模型, 由于无人机数量多, 每一台无人机与空地一体化网络传输的数据量大, 直接将 6G 混合信号作为训练数据去训练机器学习模型的话, 无疑增加了机器学习模型的训练复杂度和时间, 也增加了无人机的功耗。因此, 首先采用 VMD 技术构建自适应信号分解模型, 将接收到的 6G 网络毫米波信号分解为若干个不同频率范围的 IMF 子信号 (模态), 使每个模态信号的带宽最小化, 将每个 IMF 数据根据频率由高到低排列, 对排列后的 IMF 数据进行筛选和融合, 再将利用 VMD 技术分解后的 IMF 数据、无人机的发射功率以及高度等参数一起作为训练数据去训练机器学习模型, 可以降低机器学习模型的训练复杂度和时间, 减少无人机的功耗。

变分模态分解技术对接收到的 6G 网络毫米波信号进行自适应分解, 其核心思想是将复杂信号分解为若干个具有特定带宽和中心频率的 IMF, 通过构建变分模型并求解最优解, 实现信号的自适应分解。每个 IMF 模态是具有有限带宽的调幅-调频信号, 且围绕一个中心频率振荡。其目标是通过变分优化方法, 同时确定所有模态及其对应的中心频率, 最小化所有模态分量的带宽之和, 同时确保分解后的模态分量之和等于原始信号。

变分模态分解技术的目标就是要将式(5)中第 n 个无人机接收到的 6G 信号 Y_n 分解为 K 个模态分量 $u_k(t)$, 且满足式(8)。

$$Y_n(t) = \sum_{k=1}^K u_k(t) \quad (8)$$

每个模态分量 $u_k(t)$ 可以被表示为调幅-调频信号, 即

$$u_k(t) = A_k(t) \cos(\phi_k(t)) \quad (9)$$

其中, $A_k(t)$ 为幅度函数, $\phi_k(t)$ 为相位函数, 其瞬时频率 $\omega_k(t) = \frac{d\phi_k(t)}{dt}$ 。

通过希尔伯特变换将模态分量转换为解析信号, 提取单边频谱, 并用高斯平滑后的紧支撑特性

近似其带宽。模态分量 u_k 的带宽定义为其频谱的二阶矩,如式(10)所示。

$$\left\| \partial_t [(\delta(t) + \frac{j}{\pi t}) u_k(t)] e^{-j\omega_k(t)} \right\|_2^2 \quad (10)$$

其中, $\delta(t) + \frac{j}{\pi t}$ 是希尔伯特变换的冲激响应,用于将模态分量信号 $u_k(t)$ 转换为解析信号形式(即保留正频率成分),希尔伯特变换的作用是将实信号转换为复信号,以便分离幅度和相位信息; ∂_t 表示时间导数,对经过希尔伯特变换后的信号进行求导的作用是衡量每个IMF模态的瞬时频率波动,进而约束模态的带宽;将求导后的信号通过乘以复指数项 $e^{-j\omega_k(t)}$,将信号调制到基带(中心频率 ω_k 附近),等效于提取信号在中心频率 ω_k 附近的瞬时频率波动。

VMD的基本思想是将接收到的6G原始信号分解为若干个IMF模态,每个模态具有中心频率和带宽。VMD通过变分法在频域上分解信号,使每个模态的带宽最小,VMD的优化目标是通过最小化上述导数的L2范数(即 $\left\| \partial_t [(\delta(t) + \frac{j}{\pi t}) u_k(t)] e^{-j\omega_k(t)} \right\|_2^2$),迫使每个模态分量 $u_k(t)$ 的能量集中在中心频率 ω_k 附近,从而约束其带宽,可以表示为带约束项的最小化优化问题。

$$\begin{aligned} \min_{\{u_k\}, \{\omega_k\}} & \left(\left\| \partial_t [(\delta(t) + \frac{j}{\pi t}) u_k(t)] e^{-j\omega_k(t)} \right\|_2^2 \right) \\ \text{s.t.} & \sum_{k=1}^K u_k(t) = Y_n(t) \end{aligned} \quad (11)$$

通过引入拉格朗日乘数 $\lambda(t)$ 和惩罚因子 α (控制约束的严格程度),将约束问题转化为无约束优化问题。

$$\begin{aligned} \Psi(\{u_k\}, \{\omega_k\}, \lambda) = & \\ \alpha \sum_{k=1}^K & \left\| \partial_t [(\delta(t) + \frac{j}{\pi t}) u_k(t)] e^{-j\omega_k(t)} \right\|_2^2 + \\ < \lambda(t), Y_n(t) - \sum_{k=1}^K & u_k(t) > \end{aligned} \quad (12)$$

其中, $< \lambda(t), Y_n(t) - \sum_{k=1}^K u_k(t) >$ 表示内积项。若模

态之和与原始信号存在误差 $Y_n(t) - \sum_{k=1}^K u_k(t) \neq 0$,

拉格朗日乘数 $\lambda(t)$ 会通过内积项 $< \lambda(t), \bullet >$ 对目标函数施加惩罚,迫使优化过程尽可能满足该约束,

也就是通过 $\lambda(t)$ 动态调整模态分量 $u_k(t)$,使它们的和 $\sum_{k=1}^K u_k(t)$ 逼近6G原始信号 $Y_n(t)$,如果模态之和偏离 $Y_n(t)$,内积项的数值会增大,迫使算法修正模态的分解结果。

从式(12)可以看出,VMD的拉格朗日函数包含两部分。

1) 带宽约束。最小化各模态的瞬时频率波动(通过时间导数 ∂_t 实现)。

2) 重构约束。确保所有模态的叠加等于原始信号(通过 $\sum_{k=1}^K u_k(t)$ 实现)。

VMD的目标就是同时最小化模态带宽和重构误差,即

$$\begin{aligned} \arg \min & \left(\alpha \sum_{k=1}^K \left\| \partial_t [(\delta(t) + \frac{j}{\pi t}) u_k(t)] e^{-j\omega_k(t)} \right\|_2^2 + \right. \\ & \left. < \lambda(t), Y_n(t) - \sum_{k=1}^K u_k(t) > \right) \end{aligned} \quad (13)$$

其中,第一项为惩罚模态的带宽(频率波动),迫使每个模态能量集中;第二项为惩罚模态之和与原始信号的差异,确保分解的完备性。

采用迭代法交替更新各模态分量 u_k 、中心频率 ω_k 和拉格朗日乘数 λ ,步骤如下。

1) 设定分解模态数 K 、惩罚因子 α 和收敛阈值 ε ,初始化 $u_k^0, \omega_k^0, \lambda_k^0$ 。

① 由于6G信号 $Y_n(t)$ 是混合信号,先对混合信号 $Y_n(t)$ 做快速傅里叶变换(FFT, fast Fourier transform),观察频谱中能量集中到“主峰”数量,每个主峰对应一个潜在模态,如果频谱显示6个独立主峰,则 K 初步设定为6。

② 由于6G信号 $Y_n(t)$ 为超宽带信号,本文将惩罚因子 α 设定为6G系统采样频率的2倍,即 $\alpha = 2f_s$ 。

③ 收敛阈值 ε 设置为 $\varepsilon = 10^{-5}$ 。

④ 初始化模态 u_k^0 为零向量,可表示为

$$u_k^0(t) = 0, k = 1, 2, \dots, K \quad (14)$$

⑤ 初始化中心频率 ω_k^0 ,对信号频谱进行均匀采样,可表示为

$$\omega_k^0(t) = \frac{k-1}{K} \frac{\omega_{\max}}{2} \quad (15)$$

其中,信号最高频率 ω_{\max} 可以通过计算信号 $Y_n(t)$ 的傅里叶变换来确定。

⑥ 初始化拉格朗日乘数 $\lambda_k^0 = 0$ 。

2) 迭代更新

更新模态函数 u_k (频域): 固定其他模态和频率, 求解单个模态的频域最优解。

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{Y}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (16)$$

其中, $\hat{u}_i(\omega)$ 和 $\hat{\lambda}(\omega)$ 分别表示 $u_k(t)$ 和 $\lambda(t)$ 的傅里叶变换, $\hat{Y}(\omega)$ 表示信号 $Y_n(t)$ 的傅里叶变换。

① 更新中心频率 ω_k : 计算当前模态能量集中的频率点 (峰值频率)。

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (17)$$

② 更新拉格朗日乘数: 根据残差调整拉格朗日乘数, 确保信号重构精度。

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau(\hat{Y}(\omega) - \sum_{k=1}^K \hat{u}_k(\omega)) \quad (18)$$

其中, 参数 τ 为拉格朗日乘数更新的步长, 用来控制拉格朗日乘数 λ 的更新幅度, 设置为 $\tau = \frac{1}{\alpha}$ 。

③ 收敛判断: 残差小于收敛阈值 ε 或者达到设置的最大迭代次数。

$$\sum_{k=1}^K \frac{\|u_k^{n+1} - u_k^n\|_2^2}{\|u_k^n\|_2^2} < \varepsilon \quad (19)$$

如果满足式(19)的收敛条件, 则结束迭代, 否则返回第②步继续迭代, 直至达到设置好的最大迭代次数。

那么通过 VMD 技术, 将接收到的 6G 网络毫米波信号分解为若干个不同频率范围的 IMF 子信号 (模态), 使每个模态信号的带宽最小化, 将每个 IMF 数据根据频率由高到低排列, 对排列后的 IMF 数据进行筛选和融合, 频率是通过 Hilbert 变换计算各个 IMF 的瞬时频率均值得到, 幅度通过计算各 IMF 的包络均值得到。从而实现了 6G 混合信号的自适应分解。

2.2 深度学习网络资源预测分配模型

现有的一些机器学习模型在 6G 网络进行预测时, 除了直接采用 6G 混合信号作为训练数据导致训练复杂度较高和训练时间较长的问题, 还面临其

他一些挑战。首先, 无线通信数据具有高度的非线性和时序相关性, 传统的机器学习模型可能难以捕捉数据中复杂的时空特征。其次, 系统容量受多个因素的共同影响, 包括设备的移动、业务需求的变化以及信道环境参数等, 这些因素之间的复杂关系需要更加精确的建模。最后, 传统的机器学习模型可能会面临梯度消失或梯度爆炸的问题, 影响模型的训练和收敛速度。

深度学习算法中的 LSTM 是一种特殊的递归神经网络, 在处理时间序列数据方面非常有效, 旨在解决传统递归神经网络在处理长序列时存在的梯度消失和梯度爆炸问题。LSTM 是一种改进的循环神经网络, 专门用于处理具有长期依赖性的序列数据。相比传统递归神经网络, LSTM 通过引入记忆单元和 3 个门控机制 (输入门、遗忘门和输出门) 来控制信息的流动, 确保重要信息可以长期保留, 而不重要的信息被遗忘, 记忆单元和这些门控机制的引入使 LSTM 能够有效地处理长序列数据, 并学习和保存重要的历史信息, 从而更好地进行预测。

搭建 LSTM 模型, 利用 VMD 技术分解后的 IMF 数据、空中基站的发射功率以及高度等参数一起作为训练数据去训练 LSTM 模型, 构建无人机辅助的 6G 空地一体化网络资源预测模型, 对网络资源进行预测分配, 然后根据 LSTM 模型的预测结果调整无人机的位置以满足网络容量最大化的需求。

1) 数据预处理单元

首先对 VMD 技术分解后的 IMF 数据进行预处理。

① 剔除异常值 (如特征值超出合理范围的样本)。

② 填补缺失值 (线性插值或均值填充)。

③ 对频率和幅度进行 min-max 归一化至 [0,1] 区间, 避免模型训练时出现梯度消失或梯度爆炸。

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (20)$$

2) LSTM 输入训练数据封装单元

① 数据封装单元的作用是将经过数据预处理单元的频率和幅度数据, 以及无人机的发射功率和高度等参数按历史时间步 T 构建成训练数据矩阵 $\mathbf{R}^{T \times (2K + 2N + 1)}$, 历史时间步 T 为 6G 信号的调制周期, K 为模态数目, N 为无人机的数目, 训练数据矩阵可以表示为

$$\mathbf{R}^{T \times (2K + 2N + 1)} = \begin{bmatrix} t_1 & x_1^f & x_1^\sigma & x_2^f & \dots & x_K^\sigma & \text{UAV}_1^{P_1} & \dots & \text{UAV}_N^{P_N} & \text{UAV}_1^{H_1} & \dots & \text{UAV}_N^{H_N} \\ t_2 & x_1^f & x_1^\sigma & x_2^f & \dots & x_K^\sigma & \text{UAV}_1^{P_1} & \dots & \text{UAV}_N^{P_N} & \text{UAV}_1^{H_1} & \dots & \text{UAV}_N^{H_N} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ t_T & x_1^f & x_1^\sigma & x_2^f & \dots & x_K^\sigma & \text{UAV}_1^{P_1} & \dots & \text{UAV}_N^{P_N} & \text{UAV}_1^{H_1} & \dots & \text{UAV}_N^{H_N} \end{bmatrix} \quad (21)$$

其中, t_i 表示历史时间, x_i^f 和 x_i^σ 分别表示 6G 接收信号 x_i 的频率和幅度, $\text{UAV}_i^{P_i}$ 和 $\text{UAV}_i^{H_i}$ 分别表示无人机 UAV_i 的发射功率和高度。

② 构建时间序列。定义训练数据时间窗口 W (6G 信号为高频信号, 本文方案中 $W=20T$, 其中 T 为 6G 信号的调制周期), 构建 LSTM 的输入训练数据集和输出结果, 分别表示为

$$\mathbf{X} = \begin{bmatrix} \mathbf{R}_{T_1} \\ \mathbf{R}_{T_2} \\ \vdots \\ \mathbf{R}_{20} \end{bmatrix}_{20T \times (2K + 2N + 1)} \quad (22)$$

$$\mathbf{Y} = \begin{bmatrix} \text{UAV}_1^{B_1} & \dots & \text{UAV}_N^{B_N} \\ \text{UAV}_1^{P_1} & \dots & \text{UAV}_N^{P_N} \\ \text{UAV}_1^{H_1} & \dots & \text{UAV}_N^{H_N} \end{bmatrix}_{3 \times N} \quad (23)$$

③ 将输入训练数据集划分为训练集 (约 70%)、验证集 (约 20%) 和测试集 (约 10%), 训练集用于模型参数学习, 验证集用于调整超参数 (如 LSTM 层数、学习率), 测试集用于评估模型泛化能力。

3) 网络资源分配预测单元

① LSTM 模型构建

输入层: 接收 LSTM 输入训练数据封装单元输出的训练数据集 X , 维度为 $20T \times (2K + 2N + 1)$ 。

LSTM 层: 堆叠 3 层 LSTM 单元, 每层设置 128 个隐藏单元数, 捕捉时间序列的长期依赖关系。

全连接层: 将 LSTM 输出映射到预测目标, 预测网络资源分配方案 (如无人机发射功率、无人机飞行高度等), 全连接层使用线性激活函数, 输出连续值。

② LSTM 模型训练优化

使用训练集对 LSTM 模型进行迭代训练, 设置批量大小为 64, 训练轮数为 200。

在训练 LSTM 模型时, 使用均方误差 (MSE, mean square error) 作为损失函数, 均方误差的计算式为

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2 \quad (24)$$

优化目标是多目标优化, 采用加权组合来实现目标。

$$E = \min (\zeta_1 \text{MSE}_{\text{带宽}} + \zeta_2 \text{MSE}_{\text{功率}} + \zeta_3 \text{MSE}_{\text{高度}}) \quad (25)$$

其中, ζ_1 、 ζ_2 和 ζ_3 分别表示无人机分配带宽、发射功率和高度各自均方误差的权值, 初始值都设置为 $\frac{1}{3}$ 。

LSTM 模型每轮训练后, 通过计算式(25)来评估模型的性能, 通过网格搜索或随机搜索调整超参数, 如 LSTM 层数、隐藏单元数、权值等参数, 目标是让式(25)的 E 值越来越小, 直到式(25)的 E 值不再下降就停止训练, 避免过拟合。这个时候得到的超参数组合就是最终参数, 得到的 LSTM 模型作为最优模型。同时为了防止长时间训练, 本文设置最大训练轮数为 200, 如果达到最大训练轮数, 也将强制停止训练。

③ 网络资源分配预测

将实时采集的混合信号经 VMD 技术处理后, 输入训练好的 LSTM 模型, 得到未来时段 (如 5 min 后) 的网络资源预测值 (如无人机带宽分配、发射功率和高度)。

2.3 网络资源实时动态更新模型

虽然使用 VMD-LSTM 联合算法得到了网络资源预测模型, 但是因为网络中设备位置、业务需求和信道环境参数会实时变化, 会出现因为 6G 信号特征快速变化导致的预测滞后问题。为了解决这个问题, 本节建立深度 Q 网络强化学习模型, 利用深度强化学习的实时在线学习能力, 根据设备位置、业务需求变化以及各种信道环境参数的变化实时优化调整深度学习的决策过程, 实时动态调整无人机的位置和网络资源的分配策略, 使算法具备自适应环境感知能力, 能够根据无人机的实时位置、速度、电池寿命和周围环境信息自主做出最优决策, 使其能够预测网络变化并实时调整无人机的位置和资源配置策略, 以解决 6G 信号特征快速变化导致的预测滞后问题, 应对用户行为模式的变化、环境干扰以及无人机的移动性。

采用 DQN 作为强化学习的框架, 结合上述设计的 VMD-LSTM 模型资源预测分配决策, 定义一个合适的奖励函数, 该函数根据网络性能和资源利用率来评估不同的资源分配策略。通过不断试错和反馈, 强化学习机制将指导 DQN 逐步调整其输出策略, 以最大化长期累积奖励。

1) 定义问题与环境建模

① 状态空间 S

定义: 包含无人机位置 (经纬度、高度)、网络资源状态 (无人机的分配带宽、发射功率)、VMD 提取的信号特征 (频率、幅度、调制方式)。

$$s_t = [H_{t,i}, B_{t,i}, P_{t,i}, x_j^f, x_j^a] \quad (26)$$

其中, $H_{t,i} = [x_{t,i}, y_{t,i}, z_{t,i}]$ 表示无人机 i 在 t 时刻的高度, 用三维坐标表示; $B_{t,i}$ 和 $P_{t,i}$ 分别表示无人机 i 在 t 时刻的带宽和发射功率; x_j^f 和 x_j^a 分别表示第 j 个信号的频率和幅度。

② 动作空间 A

定义: 无人机移动方向 (8 个方向, 如北、东北、东等) 和网络资源分配策略 (如无人机带宽分配比例和发射功率)。

$$a_{t,i} = [\text{dir}_{t,i}, l_{t,i}, m_{t,i}] \quad (27)$$

其中, $\text{dir}_{t,i}$ 表示无人机 i 在时刻 t 的移动方向 (8 个方向用离散值 0~7 表示), $l_{t,i}$ 和 $m_{t,i}$ 分别表示第 i 个无人机带宽分配比例和发射功率权重, 满足 $\sum_{i=1}^N l_{t,i} = 1$

和 $\sum_{i=1}^N m_{t,i} = 1$ 。

③ 奖励函数

定义: 衡量动作对网络容量最大化目标的贡献, 结合网络吞吐量、干扰抑制、无人机能耗等因素。

$$R_t = q_1 \text{Throughput}_t - q_2 \text{Interference}_t - q_3 \text{Energy}_t \quad (28)$$

其中, Throughput_t 表示 6G 空地一体化网络总吞吐量, Interference_t 表示干扰强度之和, Energy_t 表示无人机能耗, q_1, q_2, q_3 为权重系数 ($q_1 = q_2 = q_3 = \frac{1}{3}$)。

2) 构建深度 Q 网络

① 网络结构

输入层: 接收状态 s_t , 其维度与状态空间大小一致。

隐藏层: 可根据状态特征选择全连接层或卷积层 (当状态含图像化特征时), 设置为 3 层, 每层神经元数量设为 128。

输出层: 输出每个动作的 Q 值, 维度为动作空间大小 $|A|$, 从而为每个可能动作提供价值评估。

② Q 值计算

定义: Q 值用于评估在特定状态下采取某个动作的长期价值。

$$Q(s_t, a_t; \theta) = \text{output}(\text{FC}(\text{ReLU}(\text{FC}(s_t; \theta_1)); \theta_2)) \quad (29)$$

其中, θ_1 表示第一个全连接层 $\text{FC}(s_t; \theta_1)$ 的参数集合 (包括权重矩阵和偏置向量), θ_2 表示第二个全连接层 $\text{FC}(\text{ReLU}(\text{FC}(s_t; \theta_1)); \theta_2)$ 的参数集合 (包括权重矩阵和偏置向量), θ_1 和 θ_2 通过反向传播进行更新, 以控制参数更新的步长和速度。FC 表示全连接层, “ReLU” 表示激活函数 $\text{ReLU}(x) = \max(0, x)$ 。

3) 训练过程

① 经验回放

定义: 经验回放机制通过存储状态-动作-奖励-下一状态四元组 (s_t, a_t, r_t, s_{t+1}) 到经验池 D , 并随机采样进行训练, 能够有效打破数据间的相关性, 提高算法稳定性。

首先执行动作 a_t , 获取奖励 r_t 和下一状态 s_{t+1} ; 接着将四元组存入经验池 D ; 最后从经验池 D 中随机采样一批数据 (如 32 个样本) 用于网络训练。

② 目标网络

定义: 目标网络通过复制主网络参数, 并定期更新 (如每 100 步), 用于计算目标 Q 值, 从而减少训练过程中的不稳定。

$$y_t = r_t + \gamma \max_{a'_t} Q(s_{t+1}, a'_t; \theta^-) \quad (30)$$

其中, γ 为折扣因子, 取值 0.97, 用于平衡短期与长期奖励, θ^- 为目标网络参数。

③ 损失函数与优化

定义: 损失函数采用 MSE, 用于衡量预测 Q 值与目标 Q 值的差异。

$$\Delta(\theta) = \frac{1}{N} \sum_{i=1}^N (Q(s_i, a_i; \theta) - y_i)^2 \quad (31)$$

选用 Adam 优化器对参数 θ_1 和 θ_2 进行更新, 它

是一种自适应学习率的优化算法,能够在训练过程中自动调整学习率。Adam 优化器的更新式为

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (32)$$

$$\eta_t = \beta_2 \eta_{t-1} + (1 - \beta_2) g_t^2 \quad (33)$$

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (34)$$

$$\hat{\eta}_t = \frac{\eta_t}{1 - \beta_2^t} \quad (35)$$

$$\theta_{t+1} = \theta_t - \frac{\mu}{\sqrt{\hat{\eta}_t + \zeta}} \hat{m}_t \quad (36)$$

其中, m_t 和 η_t 分别是梯度的一阶矩估计和二阶矩估计; β_1 和 β_2 是指数衰减率, $\beta_1 = 0.9$, $\beta_2 = 0.999$; g_t 是当前时刻的梯度; μ 是学习率, $\mu = 0.001$, ζ 是探索率,用于平衡探索与利用,初始时较高的探索率有助于算法广泛探索不同的动作和状态,通过迭代更新参数,使网络不断学习并优化决策能力。

4) 算法步骤

算法 1 网络资源实时动态更新

- ① 初始化系统参数: 主网络 $Q(s_t, a_t; \theta)$ 和目标网络 $Q(s_t, a_t; \theta^-)$, 令 $\theta^- = \theta$; 经验池 D 容量设置为 10 000; 探索率 ζ 初始值设置为 0.9
- ② for i 从 1 到 1 000 循环
- ③ 以探索率 ζ 随机选择动作, 促进算法对环境的探索; 否则选择当前 Q 值最大的动作 $a_t = \arg \max Q(s_t, a; \theta)$, 以利用当前学习到的知识。同时, 逐渐减小探索率 ζ (如每 100 步乘以 0.99), 随着训练的进行减少探索, 增加对已学习到的最优动作的利用
- ④ 执行选定的动作 a_t , 获取相应的奖励 r_t 和下一状态 s_{t+1} , 并将 (s_t, a_t, r_t, s_{t+1}) 存入经验池 D , 为后续训练提供数据
- ⑤ 从经验池 D 中采样一批数据, 基于采样数据计算目标 Q 值 y_t 和损失 $\Delta(\theta)$, 然后使用 Adam 优化器更新主网络参数 θ , 使网络不断优化对 Q 值的预测
- ⑥ 每 100 步将主网络参数复制给目标网络, $\theta^- = \theta$, 保持目标网络与主网络的同步, 稳定训练过程

⑦ until 式(29)收敛, MSE 不再变化

⑧ end for

5) 测试与部署

训练完成后, 固定网络参数, 此时算法已学习到较优的决策策略。在实际应用中, 根据当前状态选择 $a_t = \arg \max Q(s_t, a; \theta)$ 作为最优动作, 实时调整无人机路径和资源分配, 实现高效的无人机运行与资源管理。

通过 DQN 在线深度强化学习机制, 本文将实时更新 LSTM 模型的权重和参数, 实时动态调整无人机的位置以及网络资源的分配策略, 以适应动态变化的网络环境。利用经验回放池存储状态-动作-奖励-新状态的元组, 并从中随机抽取样本来更新网络。重复 LSTM 和 DQN, 目标是让式(23)的值越来越小, 直到其不再下降, 或达到迭代次数上限。算法步骤如算法 2 所示。

算法 2 基于 VMD-LSTM-DQN 组合模型的算法步骤

- 1) 构建历史数据集: 采集 6G 网络毫米波信号数据, 数据预处理: 去重、剔除异常值 (功率、高度超出样本范围)
- 2) 初始化系统参数
 - ① VMD 参数: 模态数 $K = 6$, 惩罚因子 $\alpha = 2 \times 10^9$, 收敛阈值 $\varepsilon = 10^{-5}$, 拉格朗日更新步长 $\tau = \frac{1}{\alpha}$, 采样频率 $f_s = 10^9$ Hz
 - ② LSTM 参数: 时间窗口 $W = 20T$, T 为 6G 信号的调制周期, 隐藏单元数为 128, 堆叠层数为 3, 训练批次为 64, 最大轮数为 200, 数据集划分比例为 7:2:1
 - ③ DQN 参数: 折扣因子 $\gamma = 0.97$, 初始探索率 $\zeta = 0.9$, 经验池容量 $D = 10\ 000$, 状态维度为 $2K + 5$, 动作维度为 11
- 3) for i 从 1 到 1 000 循环
- 4) 通过 VMD 技术分解当前信号, 获取 IMF 特征
- 5) 每 10 轮训练/更新 LSTM 模型
- 6) LSTM 预测初始资源分配方案
- 7) DQN 优化资源分配, 执行动作并获取反馈
- 8) if 式(31)收敛
- 9) break
- 10) else

- 11) 调整 VMD 模块参数: 模态数 K , 在 VMD 模块重新分解信号
- 12) 微调 LSTM 模块参数: 模型权重和参数, 优化资源分配结果
- 13) end if
- 14) end for

基于 VMD-LSTM-DQN 组合模型的算法流程如图 2 所示。

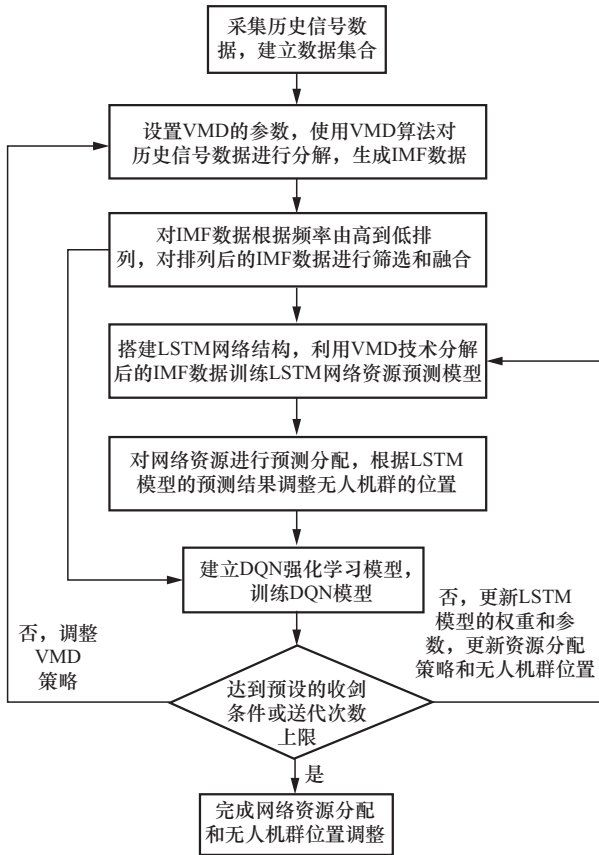


图2 基于 VMD-LSTM-DQN 组合模型的算法流程

3 仿真分析

本文方案基于成熟的深度学习和强化学习技术, 具备理论基础和技术支持, 本节通过仿真实验分析了本文方案的性能。仿真环境使用 MATLAB 中的深度网络设计器和 Reinforcement Learning Designer 来实现上述算法。首先, 定义网络结构和参数, 然后使用 MATLAB 提供的函数来构建 VMD-LSTM 和 DQN 框架。在训练过程中, 可以利用 MATLAB 的并行计算功能来加速训练过程。VMD-LSTM-DQN 仿真参数如表 2 所示, 为简化模型, 本文暂不考虑无人机的动力学约束。

参数	值
无人机的初始高度/m	100
6G 微基站数目/个	20
地面用户设备数目/个	500
6G 微基站发射功率/dBm	45
无人机的数目/个	10
无人机发射功率/mW	[50, 300]
无人机载波频率/GHz	2
无人机飞行半径/m	200
下行带宽/MHz	10
子信道数目/个	16
视距/非视距路径损耗指数/dB	3/23
噪声功率谱密度/(dBm·Hz ⁻¹)	-174
DNN 隐藏层数目/个	3
损失因子 γ	0.98
DNN 训练次数/次	3 000

假定无人机辅助的 6G 空地一体化网络中有 10 架无人机, 飞行半径是 200 m, 无人机工作模式为飞行-悬停-通信, 无人机初始的时候以圆形编队的方式悬停在高度 100 m 的低空进行通信。未来的 6G 网络将会是微基站 (MBS, mobile base station), 所以假定 6G 微基站数目为 20 个。为了模拟真实的用户稀疏分布的环境, 假定地面用户设备总数目为 500 个, 所有用户分布在 $[\pm 600, \pm 600]$ m 方形范围内。其中有 6 个用户设备比较密集的区域, 每个区域的用户设备为 50 个, 其余 200 个用户设备则随机分布在 $[\pm 600, \pm 600]$ m 方形范围内。初始仿真场景如图 3 所示, 其中, X 轴、 Y 轴和 Z 轴为三维立体坐标轴, 六角形点表示地面用户 (UE, user equipment), 菱形点表示 6G 微基站, 圆点表示 UAV。




图3 初始仿真场景

为了比较直观地验证本文算法的可行性，提供以下性能不同的算法：1) 基于梯度的资源分配算法^[20]；2) 基于贪婪策略的资源分配算法^[21]。在强化学习阶段，不考虑环境因素对无人机通信网络的影响，如风速、天气等因素，只引入因无人机自身的移动所带来的位置坐标的变化。

首先，验证 VMD 算法的性能。假设接收到的混合信号包含了 4 个 6G 毫米波信号，频率分别是 [30, 70, 150, 300] GHz，信噪比设置为 -20 dB。VMD 算法性能分析如图 4 所示。

图 4(a)和图 4(b)分别为 VMD 算法分解后信号和样本熵比较。结合两幅图的结果可以看出，所有 IMF 的样本熵均低于原始信号，表明 VMD 算法有效分离了信号成分。图 4(c)为 IMF 中心频率与样本熵关系。从图 4(c)中可以看出，IMF 样本熵呈现出良好的单调性，表明分解符合物理意义。从图 4 整体的性能分析结果来看，VMD 算法在分解 6G 混合信号的时候也表现出了很好的分解能力，能够有效分离出信号成分。信号成分被分离出来之后，就可以提取出相应的幅度和频率值，作为特征数据输

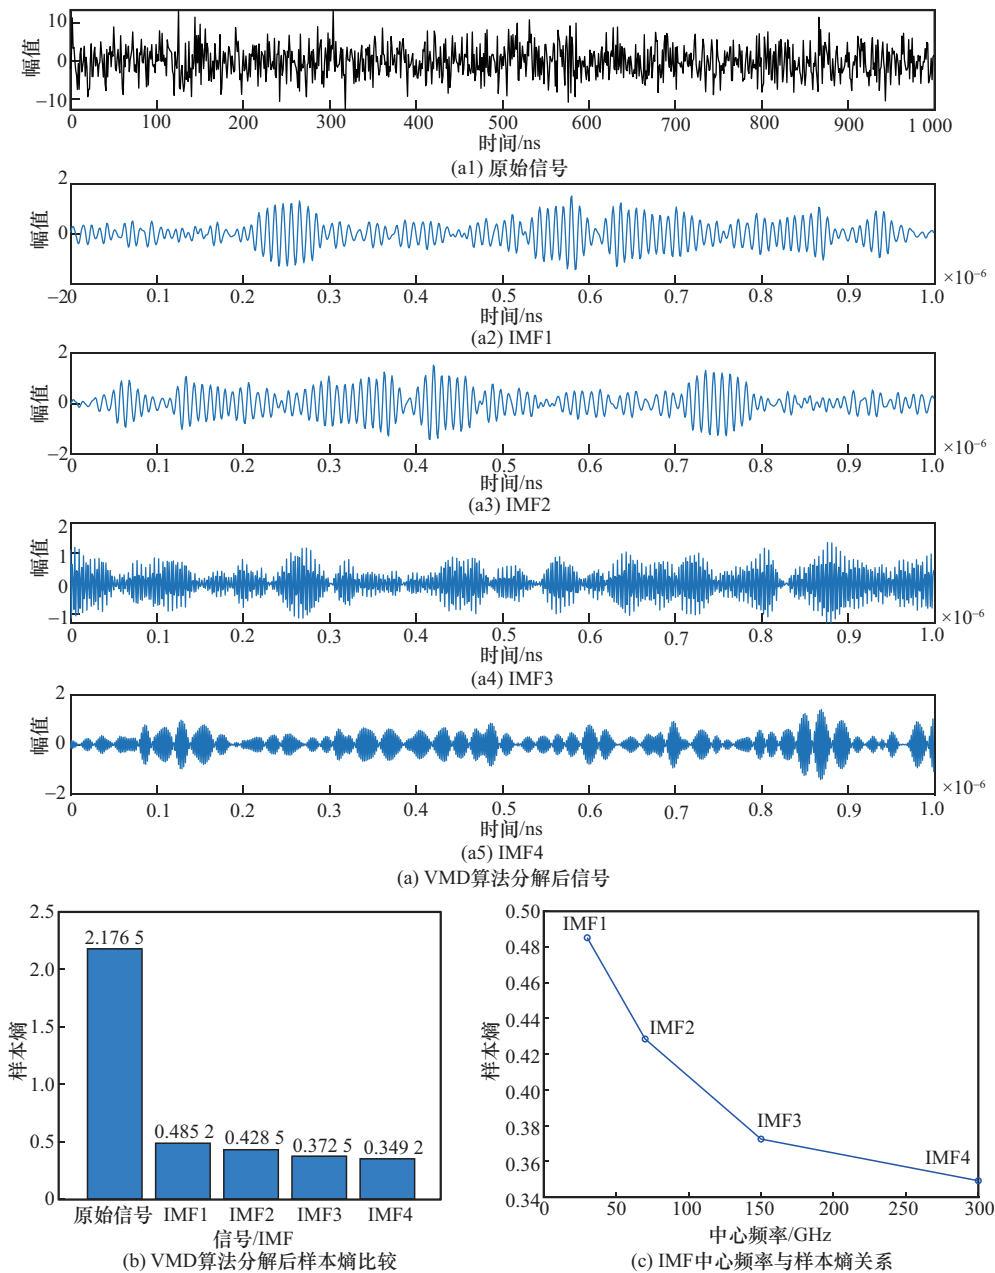


图 4 VMD 算法性能分析

入后面的 LSTM 模型中去训练模型, 降低了 LSTM 模型的训练复杂度和训练时间。

其次, 验证本文算法的收敛性, 结果如图5所示。从图5可以看出, 随着训练次数增加, 本文算法最终会达到收敛值, 初步验证了本文算法的可行性。




图5 VMD-LSTM-DQN算法收敛性能

再次, 验证本文算法的网络吞吐量性能, 结果如图6所示。从图6可以看出, 3种算法的网络吞吐量都随着发射功率的增加而提高。这是由于每架无人机向相关设备传输更多功率, 因此在设备侧实现了高接收信干噪比 (SINR, signal to interference plus noise ratio), 从而提高了整体网络吞吐量。在这3种算法中, 本文算法实现了最佳性能, 当发射功率在较高区域时, 优势差距变得更加显著。




图6 3种算法网络吞吐量性能比较

此外, 验证本文算法的公平性指标, 结果如图7所示。这里采用网络中所有用户设备的最小数据速率被满足的概率作为公平性指标, 所有用户设备最小数据速率被满足的概率越高, 则网络的公平性越好; 反之, 网络的公平性越差。从图7可以看出, 3种算法的公平性都随着发射功率的增加而提高。这同样是因为每架无人机向相关设备传输更多

功率, 所以在设备侧实现了高接收 SINR, 从而有效地保证了设备的公平性要求。在这3种算法中, 本文算法实现了最佳性能, 当发射功率在较高区域时, 优势差距变得更加显著, 几乎接近100%。




图7 3种算法公平性指标比较

最后, 验证使用本文算法优化后无人机群的位置布置变化。无人机群初始的时候以圆形编队的方式悬停在高度为100 m的低空进行通信, 当使用本文算法优化后, 无人机群的位置变化如图8所示。

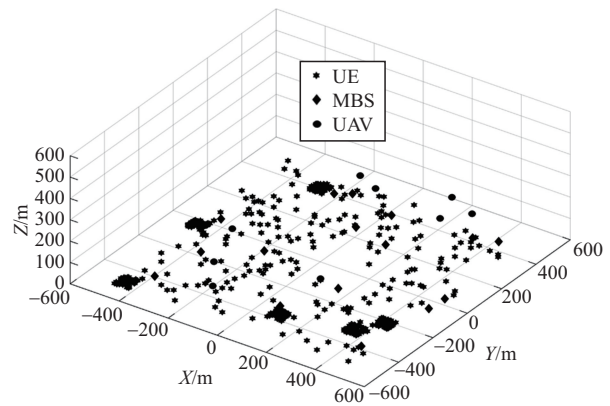


图8 无人机群的位置变化

从图8可以看出, 当网络吞吐量达到最大时, 无人机群的位置不再是以规则的圆形编队悬停进行通信了, 而是根据网络的需要分布在网络的不同地方, 高度也不相同, 这是因为使用本文算法优化后, 为了最大化网络吞吐量, 网络优化了无人机群的位置配置, 按照用户设备的业务需要将无人机布置到了最优化的位置上面。

在无人机辅助的6G地面通信系统中, 无人机的能效也是一个重要的评价指标, 因为它直接关系到无人机的续航时间、任务执行效率和网络整体性能。图9展示了无人机的网络能效随地面用户数量

的变化。3种算法的网络能效随着无人机可接入地面用户数量的增加都逐渐提高,这表明地面用户数量对无人机网络能效有显著影响。而应用本文算法后无人机网络能效明显高于其他2种算法。这表明应用本文算法可以有效优化无人机的功率分配,提高网络能效。随着地面用户数量的增加,深度Q网络在强化学习优化后的能效增长更为显著,特别是在地面用户数量较少的情况下。本文算法在使用深度学习对网络资源预测分配之后使用深度Q网络强化学习优化策略,在提高无人机网络能效方面表现良好,特别是在用户众多的情况下。这表明该算法能够有效应对地面用户数量增加带来的挑战,优化无人机的功率分配,提高UAV网络能效。同时从图9还可以看出,UAV网络能效的增长随着地面用户数量的增加而趋于稳定。这可能意味着,在地面用户数量达到一定水平后,进一步增加地面用户数量对提高UAV网络能效的影响有限。




图9 地面用户数量对无人机网络能效的影响

为了体现不同模块的重要性和贡献度,设计4组消融实验:①完整模型:VMD+LSTM+DQN;②无VMD模型:原始信号+LSTM+DQN,验证特征提取能力;③无LSTM模型:VMD+其他网络+DQN,验证时空建模能力;④无DQN模型:VMD+LSTM+其他策略,验证决策优化能力。仿真结果对比如表3所示。

从表3的仿真结果对比可以发现,完整模型性能最优:在所有指标中,完整模型的网络吞吐量最高(8.72 Gbit/s)、公平性最接近100%(0.96)和能效最高(3.85×10^6 bit/J),且收敛最快(280次迭代),验证了VMD、LSTM和DQN三模型协同的有效性。

表3 消融实验仿真结果对比

模型类型	网络吞吐量/(Gbit·s ⁻¹)	公平性	UAV网络能效/(bit·J ⁻¹)	收敛迭代次数/次
完整模型	8.72	0.96	3.85×10^6	280
无VMD模型	6.15	0.78	2.12×10^6	450
无LSTM模型	5.93	0.75	2.05×10^6	520
无DQN模型	7.01	0.82	2.76×10^6	310

VMD的贡献:无VMD模型因直接处理原始混合信号(含多频段耦合干扰),LSTM难以提取有效特征,导致网络吞吐量下降29.5%、UAV网络能效下降44.9%,证明VMD的信号分解对降低模型复杂度、提升特征纯度具有关键作用。

LSTM的贡献:无LSTM模型因无法有效捕捉6G信号的长时空依赖(如用户移动导致的信道变化趋势),网络吞吐量下降32.0%、公平性下降21.9%,体现了LSTM在时序建模上的优势。

DQN的贡献:无DQN模型因缺乏实时动态优化能力(无法根据环境变化调整资源分配),网络吞吐量下降19.6%、UAV网络能效下降28.3%,验证了DQN在决策层的优化价值。

通过消融实验可见,完整模型各模块(VMD特征提取、LSTM时空预测和DQN动态决策)均对性能有显著贡献,协同作用下相较于单一模块缺失的模型具有系统性优势。

4 结束语

本文针对无人机辅助6G空天地一体化网络的系统性能进行了研究,提出了基于VMD-LSTM-DQN组合模型的无人机辅助6G空地一体化网络多维度资源动态分配算法,从无人机辅助6G空地一体化网络的频谱资源分配、无人机位置部署、发射功率、系统容量以及公平性等方面进行研究,并分析这些关键因素对系统性能的影响,旨在解决无人机辅助6G空地一体化网络中的资源分配问题,提升网络性能,确保用户服务质量。通过联合自适应信号数据分解、长短期记忆网络和深度强化学习的算法组合模型迭代与优化,设计了一种能够自适应网络变化、动态优化资源分配的算法,解决了6G空地一体化网络数据量大、难以捕捉数据中复杂的时空特征以及6G信号特征快速变化导致的深度学习模型预测滞后3个问题,实现了对频谱、时间和空间资源的高效分配,以最大化无人机辅助6G空

地一体化网络的整体性能,同时确保地面用户的服务质量不受影响。仿真结果表明,本文算法在网络吞吐量、公平性和无人机网络能效等方面都具有较好的性能。

参考文献:

- [1] JIANG X, SHENG M, ZHAO N, et al. Green UAV communications for 6G: a survey[J]. Chinese Journal of Aeronautics, 2022, 35(9): 19-34.
- [2] ZHU B T, BEDEER E, NGUYEN H H, et al. UAV trajectory planning for AoI-minimal data collection in UAV-aided IoT networks by transformer[J]. IEEE Transactions on Wireless Communications, 2023, 22(2): 1343-1358.
- [3] ZHANG Y, SHAN H G, CHEN H B, et al. Perceptive mobile networks for standalone and cooperative UAV surveillance[J]. IEEE Transactions on Wireless Communications, 2024, 23(12): 19916-19932.
- [4] GIORDANI M, ZORZI M. Non-terrestrial networks in the 6G era: challenges and opportunities[J]. IEEE Network, 2021, 35(2): 244-251.
- [5] LIN X Q, ROMMER S, EULER S, et al. 5G from space: an overview of 3GPP non-terrestrial networks[J]. IEEE Communications Standards Magazine, 2021, 5(4): 147-153.
- [6] 王义君, 李嘉欣, 闫志颖, 等. 基于深度强化学习的移动边缘计算安全传输策略研究[J]. 通信学报, 2025, 46(4): 272-281.
WANG Y J, LI J X, YAN Z Y, et al. Research on secure transport strategy of mobile edge computing based on deep reinforcement learning[J]. Journal on Communications, 2025, 46(4): 272-281.
- [7] 刘亮, 荆腾祥, 段洁, 等. 空地一体化网络中基于联邦深度强化学习的边缘协作缓存策略[J]. 通信学报, 2025, 46(1): 93-107.
LIU L, JING T X, DUAN J, et al. Federated deep reinforcement learning-based edge collaborative caching strategy in space-air-ground integrated network[J]. Journal on Communications, 2025, 46(1): 93-107.
- [8] 许云鹏, 谢雅琪, 于然, 等. 感-通-物多目标融合应急无人机路径规划方法[J]. 通信学报, 2024, 45(4): 1-12.
XU Y P, XIE Y Q, YU R, et al. Integrated perception-communication-logistics multi-objective oriented path planning for emergency UAVs[J]. Journal on Communications, 2024, 45(4): 1-12.
- [9] ROZA M. Next G alliance report: 6G applications and use cases[J]. 2022, 1: 1-42.
- [10] VANELLI-CORALLI A, GUIDOTTI A, FOGGI T, et al. 5G and beyond 5G non-terrestrial networks: trends and research challenges[C]// Proceedings of the 2020 IEEE 3rd 5G World Forum (5GWF). Piscataway: IEEE Press, 2020: 163-169.
- [11] BIRABWA D J, RAMOTSOELA D, VENTURA N. Service-aware user association and resource allocation in integrated terrestrial and non-terrestrial networks: a genetic algorithm approach[J]. IEEE Access, 2022, 10: 104337-104357.
- [12] DAI C Q, XU J, WU J S, et al. Multi-objective intelligent handover in satellite-terrestrial integrated networks[C]// Proceedings of the 2022 IEEE International Conference on Communications Workshops (ICC Workshops). Piscataway: IEEE Press, 2022: 367-372.
- [13] JIANG H, WANG H, HU Y L, et al. Dynamic user association in scalable ultra-dense LEO satellite networks[J]. IEEE Transactions on Vehicular Technology, 2022, 71(8): 8891-8905.
- [14] LEYVA-MAYORGA I, SORET B, POPOVSKI P. Inter-plane inter-satellite connectivity in dense LEO constellations[J]. IEEE Transactions on Wireless Communications, 2021, 20(6): 3430-3443.
- [15] YAN L T, DING X J, ZHANG G X. Dynamic channel allocation aided random access for SDN-enabled LEO satellite IoT[J]. Journal of Communications and Information Networks, 2021, 6(2): 134-141.
- [16] JIANG C X, ZHU X M. Reinforcement learning based capacity management in multi-layer satellite networks[J]. IEEE Transactions on Wireless Communications, 2020, 19(7): 4685-4699.
- [17] PENG H X, WU H Q, SHEN X S. Edge intelligence for multi-dimensional resource management in aerial-assisted vehicular networks[J]. IEEE Wireless Communications, 2021, 28(5): 59-65.
- [18] AHMAD I, NARMEEN R, BECVAR Z, et al. Machine learning-based beamforming for unmanned aerial vehicles equipped with reconfigurable intelligent surfaces[J]. IEEE Wireless Communications, 2022, 29(4): 32-38.
- [19] GAO H, JIA C L, XU W J, et al. Machine learning-empowered beam management for mmWave-NOMA in multi-UAVs networks[J]. IEEE Transactions on Vehicular Technology, 2022, 71(8): 8487-8502.
- [20] ASHRAF Z, SHAHID M, AHMAD F. Gradient based optimization approach to solve reliability allocation system[C]// Proceedings of the 2021 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS). Piscataway: IEEE Press, 2021: 337-342.
- [21] RIYANDA R A, ADRIANSYAH N M, PRABOWO V S W. Greedy based radio resource allocation algorithm with water filling power control scheme in D2D underlying communication[J]. Journal of Measurements, Electronics, Communications, and Systems, 2021, 8: 1-7.

[作者简介]



管明祥 (1979-), 男, 湖北公安人, 博士, 深圳信息职业技术大学教授, 主要研究方向为空地一体化网络、人工智能和无线通信技术等。

吴舟 (1981-), 男, 江西南昌人, 博士, 深圳信息职业技术大学讲师, 主要研究方向为空地一体化网络、人工智能和无线通信技术等。

高宽栋 (1986-), 男, 河南驻马店人, 博士, 深圳信息职业技术大学讲师, 主要研究方向为雷达阵列信号处理、无线通信技术等。

戴一珏 (1992-), 女, 湖南岳阳人, 博士, 深圳信息职业技术大学讲师, 主要研究方向为人工智能、无线通信技术等。

王乐 (1979-), 女, 吉林临江人, 博士, 深圳信息职业技术大学讲师, 主要研究方向为空地通信技术等。

崔英杰 (1984-), 女, 黑龙江哈尔滨人, 深圳信息职业技术大学讲师, 主要研究方向为信号与信息处理、图像处理等。

唐辉 (1988-), 男, 湖南怀化人, 深圳信息职业技术大学高级工程师, 主要研究方向为无线通信与人工智能。