

基于粒度嵌套的多目标输电线路巡检卸载策略

谈 玲,汪海峰,宋 静,姚永雷*,许 海

(南京信息工程大学计算机学院,江苏南京 210044)

摘 要: 在电网巡检中,输电线路巡检机器人(Transmission Line Inspection Robot, TLIR)承担全覆盖式巡检任务,其长距离作业与高频数据采集对任务处理的实时性和能效提出严苛要求. 移动边缘计算(Mobile Edge Computing, MEC)通过在网络边缘部署计算与卸载能力,能够有效支撑输电线路巡检的实时数据处理. 传统巡检策略将路径规划和任务卸载视为两个独立过程进行分阶段优化,忽略了变量间的动态关联与时序联动,难以实现系统性能的全局最优. 针对 MEC 辅助密集输电线路巡检中存在的决策时序差异、任务低时延需求与系统节能难以兼顾的问题,本文提出一种基于粒度嵌套的多目标输电线路巡检卸载策略,通过构建多单一窗口嵌套于复合窗口的粒度嵌套结构,实现路径规划、任务卸载和资源分配的联合优化. 在该粒度嵌套结构中,复合窗口主要控制 TLIR 的巡检路径规划,单一窗口则依据通信状态和资源变化动态决策任务卸载与资源分配,以应对多个优化任务间的控制周期差异,确保系统时延和能耗最小化. 为实现 TLIR 的全覆盖式巡检,本文引入欧拉图策略,通过研究巡检场景的拓扑特性,构建覆盖所有电力线的最短欧拉回路,并采用李雅普诺夫优化技术将数据积压和能耗管理的长期随机优化问题逐步转化为时隙级的确定性问题. 针对优化变量间的复杂耦合与决策时序差异特性,本文进一步提出一种粒度嵌套感知的多目标自适应卸载算法(a Nested-Granularity-Aware Multi-Objective Adaptive Offloading algorithm, NGA-MOAO),将原 NP-hard 问题分解为两个子问题,并设计基于单一窗口激励反馈的跨窗口联合优化策略,通过动态调整单一窗口的任务卸载与资源分配来生成激励信号,进而在信号中叠加全覆盖硬性约束的惩罚项以引导复合窗口中的路径规划,最终实现多变量间的协同优化. 仿真结果表明,NGA-MOAO 算法在不同杆塔数量、加权系数占比和任务量激增下,时延和能耗均优于各对比方案且波动更小. 在确保全覆盖巡检的前提下,NGA-MOAO 算法相较于对比方案在巡检成本、能耗和时延上分别减少了 11.75%、15.11% 和 8.32% 以上,资源利用率提高 9.47% 以上,适用于复杂输电线路环境中的全覆盖式巡检.

关键词: 电网巡检;全覆盖;移动边缘计算;多目标;欧拉图;李雅普诺夫优化;粒度嵌套

基金项目: 国家自然科学基金(No.62271264)

中图分类号: TN929.5

文献标识码: A

文章编号: 0372-2112(2025)10-3514-15

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250268

Granularity Nested Multi-Objective Offloading Strategy for Transmission Line Inspection

TAN Ling, WANG Hai-feng, SONG Jing, YAO Yong-lei*, XU Hai

(School of Computer, Nanjing University of Information Science and Technology, Nanjing, Jiangsu 210044, China)

Abstract: In power grid inspection, the transmission line inspection robot (TLIR) undertakes full-coverage inspection tasks; its long-distance operation and high-frequency data acquisition impose stringent requirements on the real-time performance and energy efficiency of task processing. Mobile edge computing (MEC) deploys computing and offloading capabilities at the network edge and can effectively support the real-time data processing of transmission line inspection. Traditional inspection strategies treat path planning and task offloading as two independent processes optimized in separate stages, overlooking the dynamic associations and temporal couplings among variables and making it difficult to achieve a global optimum in system performance. To address the inconsistent decision timing in MEC-assisted dense transmission line inspection and the difficulty of balancing low-latency task demands with system energy saving, this paper proposes a granularity-nested multi-objective offloading strategy for transmission line inspection, which achieves joint optimization of path planning, task offloading, and resource allocation by constructing a granularity-nested structure in which multiple single win-

dows are embedded within a composite window. In this granularity-nested structure, the composite window primarily controls TLIR path planning, while the single windows dynamically decide task offloading and resource allocation according to variations in communication conditions and available resources, thereby coping with the different control periods among multiple optimization tasks and ensuring the minimization of system delay and energy consumption. To realize full-coverage inspection by the TLIR, an Eulerian-graph-based strategy is introduced which, by analyzing the topological characteristics of the inspection scenario, constructs the shortest Eulerian circuit covering all transmission lines, and Lyapunov optimization is employed to gradually transform the long-term stochastic optimization of task backlog and energy management into a deterministic problem at the time-slot level. In view of the complex coupling among optimization variables and the inconsistency of decision timing, this paper further proposes a nested-granularity-aware multi-objective adaptive offloading algorithm (NGA-MOAO), which decomposes the original NP-hard problem into two subproblems and designs a cross-window joint optimization strategy based on single-window incentive feedback, in which the single windows generate incentive signals by dynamically adjusting task offloading and resource allocation, and a penalty term encoding the hard full-coverage constraint is superimposed on these signals to guide path planning in the composite window, ultimately achieving collaborative optimization among multiple variables. Simulation results show that, under different numbers of towers, weight-coefficient proportions, and task surges, the delay and energy consumption of NGA-MOAO are both superior to those of the comparison schemes and exhibit smaller fluctuations. Under the premise of full-coverage inspection, compared with the baselines, the NGA-MOAO algorithm reduces inspection cost, energy consumption, and delay by at least 11.75%, 15.11% and 8.32%, respectively, and increases resource utilization by at least 9.47%, making it applicable to full-coverage inspection in complex transmission line environments.

Key words: power grid inspection; full coverage; mobile edge computing; multi-objective; Eulerian graph; Lyapunov optimization; nested granularity

Foundation Item(s): National Natural Science Foundation of China (No.62271264)

1 引言

在电力系统中,潜在的输电设施缺陷容易引发服务中断,对经济和社会造成严重的影响^[1],因此定期的电网巡检和及时维护至关重要.随着技术的发展,许多地区采用无人机(Unmanned Aerial Vehicle, UAV)代替人工巡检以提升效率,但其性能容易受到恶劣天气的影响.相比之下,输电线路巡检机器人(Transmission Line Inspection Robot, TLIR)采用附着移动方式,能沿电力线路稳定运行并跨越障碍物^[2],具备良好的环境适应性与抗干扰能力^[3].TLIR通过搭载高清可见光相机与红外热成像仪等传感器,采集大量图像与视频数据,生成需实时处理的计算任务,用于识别过热、绝缘老化等潜在故障^[4].然而,TLIR采用低功耗嵌入式处理平台,其本地算力与缓存空间均十分有限,难以及时处理这些计算密集型 and 时延敏感型任务^[5].

面对 TLIR 在任务处理上的计算挑战,移动边缘计算(Mobile Edge Computing, MEC)提供了有效的解决方案^[6].MEC通过在靠近数据源的基站(Base Station, BS)侧部署边缘计算能力,使计算资源受限的 TLIR 能够将任务实时卸载至 BS 处理,从而提升故障响应能力和巡检效率^[7].一些研究围绕 MEC 的计算卸载结构展开了工作^[8-10].其中,文献[9]设计了一种双层卸载框架,通过优化任务卸载和资源分配,有效避免服务器过载;文献[10]进一步采用 Lyapunov 技术稳定队列以最大化任

务完成率,降低系统能耗.在基于 MEC-TLIR 的密集输电线路巡检场景中,TLIR 的高移动性和 BS 的有限覆盖范围导致其通信与计算资源不断发生变化,如何在动态巡检网络中高效地实现任务卸载和资源分配以降低时延和能耗是亟待解决的问题.

一些文献采用联合优化任务卸载和资源分配的方式,降低系统时延或能耗^[11,12].此外,还有一些文献引入路径规划,通过合理设计巡检路径,不仅缩短了巡检时间,也在动态巡检网络中有效地优化了任务卸载时机和资源分配^[13-15].具体而言,文献[13]采用逐次凸逼近法,将单一窗口内的 UAV 航迹、任务卸载及资源分配进行联合优化,以降低巡检能耗.文献[14]制定了一种两阶段求解策略,通过两个阶段分别求解的方式将复合窗口路径规划、单一窗口任务卸载和资源分配进行协同优化.考虑到密集输电线路巡检中的计算卸载核心是巡检路径规划、任务卸载和资源分配,三者 in 空间、时间和资源约束上高度耦合,分阶段求解会导致结果次优.尤其在密集巡检与资源动态变化环境中,只有联合优化才能对卸载时机进行动态调整,从而高效利用 BS 算力,实现时延和能耗的全局权衡.例如,文献[15]提出了一种基于 5G MEC 的巡检计算卸载框架,采用上置信界算法优化单一任务卸载,提供任务积压和时延优化数据, Q 学习算法(Q-learning algorithm)基于这些数据计算奖励优化变电站内巡检点的路径规划,实现多任务目标对齐的联合优化.这一思路为本文

实现密集输电线路巡检中路径规划、任务卸载和资源分配的联合优化提供了重要启发。然而,密集输电线路巡检通常涉及复杂地形下的长距离线路工作,上述方法并未考虑线路的全覆盖与巡检密度差异,难以直接用于本文场景,需要在路径规划中进一步研究拓扑特性以确保线路的全覆盖。此外,任务卸载和资源分配是在单一窗口内对通信状态和资源变化进行动态响应,路径规划则是在复合窗口内控制 TLIR 的巡检路径,两种不同窗口的决策存在时序差异。这使得任务卸载、资源分配和路径规划的联合优化问题难以直接用马尔科夫决策过程建模。

针对决策时序差异问题,目前一些学者在不同场景中进行了探索^[16-22]。文献[16]通过主要化最小化方法在复合窗口内调整可移动天线位置,并在单一窗口上采用最大比率传输优化波束向量,实现跨窗口的分阶段求解。文献[17]将不同窗口的决策统一建模于异构多智能体框架以刻画跨窗口耦合。该框架要求变量共享状态空间,难以适用于路径规划和任务卸载等状态差异显著的场景。文献[18]和文献[19]则采用数学优化方法,分别通过块坐标下降和逐次凸近似,在不同窗口间交替优化迭代至收敛。这类方法能够将复杂耦合问题转化为小规模凸子问题进行求解,降低计算复杂度,但受限于非凸结构,所得解通常为近似最优。还有部分工作采用分层反馈优化框架^[20-22],例如文献[21]在单一窗口内通过匹配博弈和凸近似进行资源分配,并以系统速率作为回报优化 BS 部署,实现各窗口的目标对齐。文献[22]则提出一种双层强化学习协同框架,通过统一效用奖励贯通不同窗口决策,实现跨窗口优化。上述优化方法在一个周期内均不受硬性约束限制,仅需沿着奖励信号方向逐步改进策略,而在密集输电线路巡检中,路径规划必须满足全覆盖硬性约束,同时3类优化任务又高度耦合、状态结构各异,因此需设计具备上下联动能力的跨窗口联合优化策略,以引导路径规划在满足覆盖约束的同时朝着最小化目标的方向演进。

本文主要研究密集输电线路巡检中路径规划、任务卸载和资源分配的联合优化,旨在实现灵活的全覆盖式巡检。目前在联合优化中面临多重挑战:

(1)在复杂且广阔的密集输电线路巡检场景中,确保每个杆塔和电力线都被有效覆盖,实现全覆盖式巡检是关键所在;若路径管理不够合理,TLIR 可能会重复遍历已覆盖区域,造成能源浪费和巡检周期延长。

(2)由于 TLIR 的高移动性和 BS 的有限覆盖范围,TLIR 在通信范围内的可用通信资源和计算资源不断变化,一旦超出 BS 覆盖范围,TLIR 将无法卸载任务,进而导致本地负载和计算需求持续增加。

(3)TLIR 有限的电量是其在执行远距离巡检任务时的瓶颈,在确保低时延需求的同时优化能耗分配,以兼顾系统节能,是实现高效巡检的关键。

(4)任务卸载、资源分配和路径规划间存在复杂耦合与决策时序差异等挑战,路径规划还应满足全覆盖的硬性约束。该联合优化问题具备混合整数非线性特征,难以直接构建成马尔科夫决策过程。路径规划决定通信资源,任务卸载和资源分配影响能耗、时延与负载,其反过来又作用于路径规划,三者间的关联紧密而复杂,不适合独立优化。值得注意的是,本文所指的决策时序差异不同于预测任务中的多时间尺度(分辨率)输入问题,而是3类任务在控制周期与反馈粒度上的结构性差异带来的异步反馈与非线性耦合挑战。

针对挑战(1),本文拟采用欧拉图策略,通过构建最短欧拉回路实现 TLIR 在密集输电线路巡检中最短路径的全覆盖式巡检。对于挑战(2),本文引入任务缓存队列,用于存储 TLIR 在单个时隙内无法处理完的任务数据,并为此制定长期负载管理策略以动态平衡 TLIR 的长期负载状态。对于挑战(3),本文构建时延和能耗的多目标优化模型,并构造能耗虚拟队列,基于 Lyapunov 优化技术,将带长期约束的多目标优化问题转化为时隙内的确定性优化问题,实现能量的优化分配及时延和能耗间的动态权衡。关于挑战(4),本文提出“多单一窗口嵌套于复合窗口”的粒度嵌套结构,并设计基于单一窗口激励反馈的跨窗口联合优化策略,通过动态调整单一窗口的任务卸载和资源分配生成激励信号,复合窗口在信号中叠加全覆盖硬性约束的惩罚项,从而引导优化路径规划,实现多复杂变量间的解耦。

本文的主要贡献概括如下:

(1)提出了一种基于粒度嵌套的多目标输电线路巡检卸载策略,针对基于 MEC-TLIR 的密集输电线路巡检场景,采用欧拉图策略,利用其遍历特性探寻并构建覆盖所有电力线的最短欧拉回路,进而实现全覆盖式巡检。此外,将任务处理时延和能耗的多目标最小化问题表述为一个联合优化问题,即包括复合窗口变量路径规划和单一窗口变量任务卸载、资源分配,其中任务卸载同时考虑卸载决策和本地计算任务与卸载任务的比例,资源分配考虑本地计算频率和 BS 计算频率。

(2)为应对巡检任务中 TLIR 的长期数据积压和动态能耗管理挑战,本文采用任务缓存和能耗虚拟双队列机制,利用 Lyapunov 优化技术实现系统的长期稳定性和资源的高效利用,将长期的随机优化问题转化为求解每个时隙内的确定性优化问题,逐步逼近全局最优解,从而有效处理动态变化带来的不确定性,最终平衡系统性能与目标。

(3)为解决任务卸载、资源分配和路径规划多优化变量间的非线性耦合、决策时序差异和全覆盖硬性约束问题,本文设计一种粒度嵌套结构,通过单一窗口激励反馈复合窗口的跨窗口方式来协调不同窗口的优化过程,并提出一种粒度嵌套感知的多目标自适应卸载算法(a Nested-Granularity-Aware Multi-Objective Adaptive Offloading algorithm, NGA-MOAO).该算法先利用基于NSGA-II的单一窗口多目标优化算法(Single-window Multi-objective optimization algorithm based on NSGA-II, SMNSGA-II)动态求解单一窗口上的多目标卸载和资源分配问题,而后进行激励反馈,并利用双重双深度Q网络(Dueling Double Deep Q-Network, D3QN)求解复合窗口上的路径规划问题,实现整体协同优化.

2 基于粒度嵌套的多目标输电线路巡检卸载策略

如图1所示,本文研究的场景描述为一个由单个TLIR和多个BS组成的密集输电线路巡检网络,其中BS作为MEC节点,负责为TLIR提供计算卸载和通信支持.该网络被建模为一个无向连通图 $G=(V,E)$,其中 $V=\{v_1, v_2, \dots, v_i, \dots, v_{|V|}\}$ 表示杆塔集合, $E=\{l_{v_i, v_j} | v_i, v_j \in V, v_i \neq v_j\}$ 表示电力线集合,BS集合则表示为 $M=\{m_1, m_2, \dots, m_i, \dots, m_{|M|}\}$, d_{v_i, v_j} 表示杆塔 v_i 与杆塔 v_j 之间电力线的长度,若 v_i 与 v_j 之间没有直连的电力线,则 $d_{v_i, v_j} = \infty$.

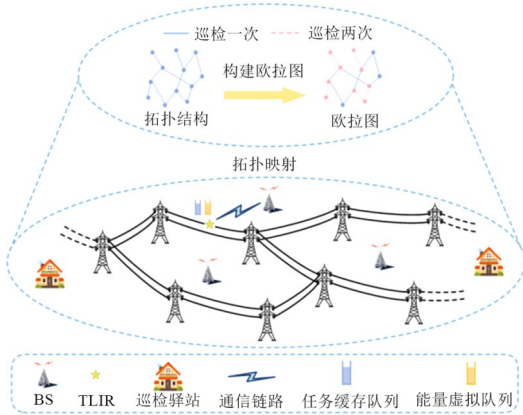


图1 基于 MEC-TLIR 的密集输电线路巡检网络

在基于 MEC-TLIR 的密集输电线路巡检网络中,TLIR从指定的杆塔出发,采用附着方式沿电力线路移动,执行包括电力线和杆塔在内的巡检任务,最后返回起始位置.需要注意的是,TLIR的巡检轨迹必须覆盖所有的电力线.如图2所示,为了更好地捕获TLIR的移动性,本文假定系统采用时隙结构,将整个巡检周期划

分为多个复合窗口,表示为 $T'=\{t'_0, t'_1, \dots, t'_i, \dots, t'_{|T'|}\}$.每个复合窗口 t'_i 的时隙长度被定义为TLIR从一个杆塔移动到另一个杆塔的巡检时间,具体取值由其路径规划决策确定.同时,每个 t'_i 被划分为几个固定时长为 Δ 的单一窗口,表示为 $T=\{t_0, t_1, \dots, t_i, \dots, t_{|T|}\}$,在每个单一窗口 t_i 内TLIR可进行任务卸载和资源分配.本文假设在每个单一窗口 t_i 内,TLIR以恒定的速度 v_r 挂载在电力线上移动,同时结合红外热成像、高清视频等技术对电力线和杆塔进行数据采集.此外,TLIR可以在本地处理计算任务,也可以通过无线方式将任务卸载到BS进行处理,并将计算结果传回TLIR.




图2 粒度嵌套结构示意图

2.1 巡检欧拉图策略

为执行全覆盖式巡检,本文采用欧拉图策略,构建TLIR从起始杆塔出发并最终返回起始杆塔的最短路径,即最短欧拉回路.为此,本文首先规定每条边只能被巡检一次.考虑到图中存在奇数度节点的情况下无法构成欧拉回路^[23],需将这些奇数度节点进行两两匹配并最小化匹配距离,通过在匹配节点之间增加一条最短路径,使得这些节点的度数变为偶数.这里采用最小二分匹配法^[24],将无向连通图 G 转化为最小权欧拉图 G^* ,二分图 $S=(V',E)$ 构建如下:

$$E = \begin{bmatrix} w_{1,1} & w_{1,2} & \dots & w_{1,n'} \\ \vdots & \ddots & & \vdots \\ w_{n',1} & w_{n',2} & \dots & w_{n',n'} \end{bmatrix} \quad (1)$$

$$w_{i,j} = \begin{cases} D_{v'_i, v'_j}, & \text{if } v'_i \neq v'_j \\ \infty, & \text{if } v'_i = v'_j \end{cases}, \forall i, j \in K \quad (2)$$

其中, $V'=\{v'_1, v'_2, \dots, v'_i, \dots, v'_{n'}\}$ 表示图 G 中奇数度节点的集合, $K=\{1, 2, \dots, n'\}$ 表示其下标的集合, n' 表示集合中的节点个数, E 表示 V' 中任意两个节点之间的最短距离矩阵, $w_{i,j}$ 表示节点 v'_i 和节点 v'_j 之间的最短距离, D 表示通过Floyd算法求得的图 G 最短距离矩阵.

进一步求解该二分图的最小权匹配,引入决策变量集合 $X=\{x_{1,1}, x_{1,2}, \dots, x_{i,j}, \dots, x_{n',n'}\}$,其中 $x_{i,j} \in \{0, 1\}$ 表示 v'_i 和 v'_j 的匹配关系, $x_{i,j}=1$ 表示匹配,此时需要构建一条 v'_i 到 v'_j 之间的最短路径,使得节点的度数为偶数, $x_{i,j}=0$ 则无需任何操作,可构建最小权欧拉图的数学模型如下:

$$\begin{aligned}
\text{P1: } \arg \min_{\{X\}} \sum_{i=1}^{n'} \sum_{j=1}^{n'} w_{i,j} x_{i,j} & \quad \lim_{t_i \rightarrow t_n} Q(t_i) \leq Q_{\max} \quad (6) \\
\text{s.t. } \left\{ \begin{array}{l} \text{C1: } x_{i,j} \in \{0, 1\}, \quad \forall i \in K, j \in K \\ \text{C2: } x_{i,j} = x_{j,i}, \quad \forall i \in K, j \in K \\ \text{C3: } \sum_{i=1}^{n'} x_{i,j} = 1, \quad \forall j \in K \\ \text{C4: } \sum_{j=1}^{n'} x_{i,j} = 1, \quad \forall i \in K \end{array} \right. & \quad (3)
\end{aligned}$$

其中, C1 表示节点匹配决策变量, C2 表示边矩阵对称约束, C3 和 C4 表示单节点仅需添加一条边。

通过求解 P1, 得到奇数度节点集合的两两匹配结果, 再结合路径矩阵 \mathbf{P} , 可得到需要添加的最小加权边集合 E' . 将 E' 与 E 合并得到集合 E^* , 进而生成图 1 所示网络的最小权欧拉图 $G^*=(V, E^*)$, 其中红色的边表示该线路巡检两次, 蓝色的边表示仅巡检一次. E^{visit} 表示 E^* 中边的访问次数矩阵, $E_{i,j}^{\text{visit}}$ 表示在整个巡检周期内, TLIR 可以遍历电力线 l_{v_i, v_j} 的次数。

在该 TLIR 巡检网络中, TLIR 的移动能耗主要由克服滚轮与电力线之间的滚动摩擦以及克服风阻所消耗的能量组成. TLIR 在第 t_i 个单一窗口内的移动能耗 $E_{\text{move}}(t_i)$ 可计算如下:

$$E_{\text{move}}(t_i) = C_r m_r g v_r \Delta + \frac{1}{2} \rho_{\text{air}} v_r^3 C_d A_r \Delta \quad (4)$$

其中, C_r 表示滚动摩擦系数, m_r 表示 TLIR 的质量, g 表示重力加速度, ρ_{air} 表示空气密度, C_d 表示风阻系数, A_r 表示 TLIR 迎风面的投影面积。

2.2 任务缓存队列

为解决单一窗口 Δ 内 TLIR 无法处理完所有任务的问题, 本文引入任务缓存队列 $Q(t_i)$, 用以存储未处理完的数据. 第 t_i 个单一窗口内收集到的任务量 $c(t_i)$ 会在该单一窗口未存入 $Q(t_i)$ 中. 不失一般性, 本文认定 $c(t_i)$ 服从同一个均值为 μ , 标准差为 σ_1 , 截断区间为 $[c(t_i)_{\min}, c(t_i)_{\max}]$ 的截断正态分布. 由于本地和 BS 计算资源有限, 本文采用分布式计算策略处理 $Q(t_i)$ 中的任务. 具体而言, 一部分任务通过本地计算, 比例为 $\rho_{\text{loc}}(t_i)$; 一部分任务则卸载到 BS 进行计算, 比例为 $\rho_{\text{un}}(t_i)$. $Q(t_{i+1})$ 为

$$\begin{aligned}
Q(t_{i+1}) &= \max \left\{ Q(t_i) - (D_{\text{loc}}(t_i) + D_{\text{un}}(t_i)), 0 \right\} + c(t_i) \\
&= \max \left\{ (1 - \rho_{\text{loc}}(t_i) - \rho_{\text{un}}(t_i)) Q(t_i), 0 \right\} + c(t_i) \quad (5)
\end{aligned}$$

其中, $Q(t_0) = 0$, $D_{\text{loc}}(t_i) = \rho_{\text{loc}}(t_i) Q(t_i)$ 表示在第 t_i 个单一窗口内本地计算的任务量, $D_{\text{un}}(t_i) = \rho_{\text{un}}(t_i) Q(t_i)$ 表示卸载到 BS 的任务量. 若 TLIR 在某个单一窗口内收集到的任务量大于本地和 BS 能够计算的任务量, $Q(t_i)$ 就会随时间单调递增, 由于任务缓存队列存在上限 Q_{\max} , 需要考虑长期稳态约束:

2.3 计算模型

TLIR 本地计算任务的时延和能耗取决于其计算资源和任务的分配. 本地计算时延 $T_{\text{loc}}(t_i)$ 为

$$T_{\text{loc}}(t_i) = \frac{F_{\text{loc}}(t_i)}{f_{\text{loc}}(t_i)} \quad (7)$$

其中, $F_{\text{loc}}(t_i) = D_{\text{loc}}(t_i) s$ 表示本地计算所需的 CPU (Central Processing Unit) 周期数, s 表示每计算一位数据所需的 CPU 周期数^[25], $f_{\text{loc}}(t_i) \in [f_{\text{loc}}^{\min}(t_i), f_{\text{loc}}^{\max}]$ 表示 TLIR 在第 t_i 个单一窗口内的 CPU 周期频率, f_{loc}^{\max} 为固定值, $f_{\text{loc}}^{\min}(t_i) = F_{\text{loc}}(t_i) / \Delta$ 表示在一个 Δ 内处理完任务所需的最小计算频率. 本地计算能耗 $E_{\text{loc}}(t_i)$ 表述为

$$E_{\text{loc}}(t_i) = \kappa_1 f_{\text{loc}}^2(t_i) F_{\text{loc}}(t_i) \quad (8)$$

其中, κ_1 由 TLIR 的 CPU 参数决定^[26].

如果在第 t_i 个单一窗口内, BS 接收到 TLIR 卸载的任务, 那么 BS 处理任务的计算时延 $T_{\text{BS}}(t_i)$ 可表示为

$$T_{\text{BS}}(t_i) = \frac{F_{\text{un}}(t_i)}{f_M(t_i)} \quad (9)$$

其中, $f_M(t_i) \in [f_m^{\min}(t_i), f_m^{\max}]$ ($m \in M(t_i)$) 表示第 t_i 个单一窗口内 BS 为接收任务分配的 CPU 计算资源, f_m^{\max} 表示计算频率上限. 考虑到密集输电线路所处地理环境复杂, f_m^{\max} 取值根据不同的地形进行差异化设置. 若 BS 需要同时承担传输和处理任务, 那么可以在某个 Δ 内, 先传输数据, 再进行任务处理, $f_m^{\min}(t_i) = F_{\text{un}}(t_i) / (\Delta - T_{\text{tran}}(t_i))$ 表示接收数据后对任务进行处理所需的最小计算频率. BS 的计算能耗 $E_{\text{BS}}(t_i)$ 表述如下:

$$E_{\text{BS}}(t_i) = \sum_{j=m_1(t_i)}^{m_{|M(t_i)|}(t_i)} a_j(t_i) \kappa_2 f_M^2(t_i) F_{\text{un}}(t_i) \quad (10)$$

其中, κ_2 由 BS 的 CPU 参数决定, 为避免高能耗低产出的计算行为, 定义能源效率约束如下:

$$\frac{D_{\text{un}}(t_i)}{E_{\text{BS}}(t_i)} \geq \xi_{\min} \quad (11)$$

其中, ξ_{\min} 表示最小计算能源效率阈值.

2.4 通信卸载模型

考虑到 TLIR 的高移动性和 BS 的有限覆盖范围, TLIR 无法保证在每个单一窗口内都能把任务卸载给某个 BS. 设集合 $M(t_i) = \{m_1(t_i), m_2(t_i), \dots, m_i(t_i), \dots, m_{|M(t_i)|}(t_i)\}$ 表示 TLIR 在第 t_i 个单一窗口内可以卸载的 BS 集合, 其中 $m_i(t_i) \in M$, 同时 $M(t_i)$ 有可能是空集. 这里用二元指标 $a_j(t_i)$ 来表示 TLIR 卸载的决策变量. 如果 TLIR 在第 t_i 个单一窗口内选择第 j 个 BS 进行任务卸载 ($j \in M(t_i)$), 则令 $a_j(t_i) = 1$, 否则 $a_j(t_i) = 0$. 值得注意的是, 在第 t_i 个单一窗口内, TLIR 最多只能卸载给一个 BS, 因此 $a_j(t_i)$ 存在以下约束:

$$a_j(t_i) \in \{0, 1\}, j \in M(t_i) \quad (12)$$

$$\sum_{j=m_1(t_i)}^{m_{u(t_i)}(t_i)} a_j(t_i) = \begin{cases} 1, & M(t_i) \neq \emptyset \\ 0, & M(t_i) = \emptyset \end{cases} \quad (13)$$

卸载任务会造成额外的通信开销,包括传输时延和能耗.传输时延分为在上行链路传输数据所需的时延 T_{tran} 以及在下行链路 BS 传回计算结果的时延 T_{back} . 由于 T_{back} 远小于 T_{tran} , 可以被忽略^[27]. 同样,传输能耗也主要考虑上行链路 TLIR 到 BS 之间传输数据所消耗的能量.在 TLIR 巡检网络中,第 t_i 个单一窗口内 TLIR 向第 j 个 BS 发送任务数据的传输速率 $r_j(t_i)$ 可由下式给出:

$$r_j(t_i) = B_w \log_2 \left(1 + \frac{pH_j(t_i)}{\sigma^2} \right) \quad (14)$$

其中, B_w 表示带宽; p 表示 TLIR 的传输功率; $H_j(t_i) = \alpha_0 d_j^{-2}(t_i)$ 表示在第 t_i 个单一窗口内 TLIR 和 BS 之间的信道功率增益,与距离平方成反比; α_0 表示单位信道功率增益^[28]; σ^2 表示高斯白噪声; $d_j^2(t_i) = (x_r(t_i) - x_j)^2 + (y_r(t_i) - y_j)^2 + (z_r(t_i) - z_j)^2$ 表示在第 t_i 个单一窗口内 TLIR 和第 j 个 BS 的三维距离; $(x_r(t_i), y_r(t_i), z_r(t_i))$ 为 TLIR 的三维坐标; (x_j, y_j, z_j) 为 BS 的三维坐标. TLIR 在第 t_i 个单一窗口内向 BS 传输数据消耗的传输时延 $T_{\text{tran}}(t_i)$ 计算如下:

$$T_{\text{tran}}(t_i) = \sum_{j=m_1(t_i)}^{m_{u(t_i)}(t_i)} a_j(t_i) \frac{D_{\text{un}}(t_i)}{r_j(t_i)} \quad (15)$$

此外,TLIR 在第 t_i 个单一窗口内向第 j 个 BS 传输数据的能耗 $E_{\text{tran}}(t_i)$ 计算如下:

$$E_{\text{tran}}(t_i) = pT_{\text{tran}}(t_i) \quad (16)$$

综上,第 t_i 个单一窗口内的总时延表示如下:

$$T_{\text{total}}(t_i) = \max \{ T_{\text{loc}}(t_i), T_{\text{tran}}(t_i) + T_{\text{BS}}(t_i) \} \quad (17)$$

第 t_i 个单一窗口内的总能耗表示如下:

$$E_{\text{total}}(t_i) = E_{\text{loc}}(t_i) + E_{\text{tran}}(t_i) + E_{\text{BS}}(t_i) \quad (18)$$

TLIR 在整个周期 $t_{|T}$ 内的能耗受限于电池容量 E_{max} , 可表示成如下约束:

$$\sum_{t_i=t_0}^{t_{|T}} (E_{\text{loc}}(t_i) + E_{\text{tran}}(t_i) + E_{\text{move}}(t_i)) \leq E_{\text{max}} \quad (19)$$

2.5 问题构建

在给定 TLIR 巡检网络拓扑后,实现各种约束下能耗和时延双重目标的核心挑战是联合优化 TLIR 的卸载决策、本地计算任务比例、本地计算频率、卸载任务比例、BS 计算频率以及每个复合窗口的路径规划,因此本文构建一个多目标多约束优化问题.若 TLIR 在第 t'_i 个复合窗口起始时所处的杆塔节点为 $P_{t'_i}$, 则其下一个复合窗口起始时的杆塔节点 $P_{t'_{i+1}}$ 由该时刻的路径规划决

定.假设 $P_{t'_i}$ 已知,整个巡检周期内的路径规划决策可以表示为 $P = \{P_{t'_1}, P_{t'_2}, \dots, P_{t'_{|T}}\}$. 优化变量集合为 $\{A, U, F, P\}$, 其中 $A = \{a_{m_1(t_i)}(t_i), a_{m_2(t_i)}(t_i), \dots, a_{m_{u(t_i)}(t_i)}(t_i)\}$, $U = \{\rho_{\text{loc}}(t_i), \rho_{\text{un}}(t_i)\}$, $F = \{f_{\text{loc}}(t_i), f_{\text{M}}(t_i)\}$. 每个单一窗口内最小化总时延和总能耗的多目标优化问题可以表示如下:

$$\begin{aligned} \text{P2: } & \arg \min_{\{A, U, F\}} \{T_{\text{total}}(t_i), E_{\text{total}}(t_i)\} \\ & \text{s.t. } \left\{ \begin{array}{l} \text{C5: } a_j(t_i) \in \{0, 1\}, j \in M(t_i) \\ \text{C6: } \sum_{j=m_1(t_i)}^{m_{u(t_i)}(t_i)} a_j(t_i) = \begin{cases} 1, & M(t_i) \neq \emptyset \\ 0, & M(t_i) = \emptyset \end{cases} \\ \text{C7: } 0 \leq \rho_{\text{loc}}(t_i) + \rho_{\text{un}}(t_i) \leq 1 \\ \text{C8: } 0 \leq \rho_{\text{loc}}(t_i) \leq \rho_{\text{loc}}^{\text{max}}(t_i) \\ \text{C9: } 0 \leq \rho_{\text{un}}(t_i) \leq \rho_{\text{un}}^{\text{max}}(t_i) \\ \text{C10: } f_{\text{loc}}^{\text{min}}(t_i) \leq f_{\text{loc}}(t_i) \leq f_{\text{loc}}^{\text{max}} \\ \text{C11: } f_{\text{M}}^{\text{min}}(t_i) \leq f_{\text{M}}(t_i) \leq \sum_{j=m_1(t_i)}^{m_{u(t_i)}(t_i)} a_j(t_i) f_i^{\text{max}} \\ \text{C12: } \frac{D_{\text{un}}(t_i)}{E_{\text{BS}}(t_i)} \geq \zeta_{\text{min}} \\ \text{C13: } \sum_{t_i=t_0}^{t_{|T}} (E_{\text{loc}}(t_i) + E_{\text{tran}}(t_i) + E_{\text{move}}(t_i)) \leq E_{\text{max}} \\ \text{C14: } \lim_{t_i \rightarrow t_{|T}} Q(t_i) \leq Q_{\text{max}} \end{array} \right. \quad (20) \end{aligned}$$

其中, C5 表示 TLIR 的卸载决策变量, C6 规定在任一单一窗口内 TLIR 最多只能卸载至一个 BS, C7 是计算比例总约束. 针对变量 $\rho_{\text{loc}}(t_i)$ 和 $\rho_{\text{un}}(t_i)$, 无论在本地还是 BS 端, 若计算任务量超出其计算能力, 就会导致任务数据在单一窗口内未处理完而发生溢出. 为避免这种情况发生, 本文基于不同节点的计算能力上限 f_i^{max} , 获得计算比例上限, 即 $\rho_{\text{un}}^{\text{max}}(t_i) = \sum_{j=m_1(t_i)}^{m_{u(t_i)}(t_i)} a_j(t_i) \Delta r_j f_j^{\text{max}} / (Q(t_i)(sr_j + f_j^{\text{max}}))$ 和 $\rho_{\text{loc}}^{\text{max}}(t_i) = \Delta f_{\text{loc}}^{\text{max}} / (sQ(t_i))$, 进而得到约束 C8 和 C9. C10 和 C11 分别表示本地计算频率和 BS 计算频率的约束, C12 表示能源效率约束, C13 表示 TLIR 的长期能耗上限约束, C14 表示任务缓存队列稳态约束.

通过求解 P2, 本文可以得到每个单一窗口内时延和能耗的联合最优解以及对应的决策 $\{A(t_i), U(t_i), F(t_i)\}$, 可用如下函数公式表示:

$$\begin{aligned} h(t_i) &= f(A(t_i), U(t_i), F(t_i)) \\ &= \eta (\lambda_1 \varphi_1 T_{\text{total}}(t_i) + \lambda_2 \varphi_2 E_{\text{total}}(t_i)) \end{aligned} \quad (21)$$

其中, $h(t_i)$ 表示每个单一窗口内的最少成本, 即时延和能耗的线性加权和, 是一个无量纲变量; λ_1 和 λ_2 表示加权系数; φ_1 和 φ_2 表示归一化因子; η 表示放大系数. 获得单一窗口内的联合最优解后, 对 $h(t_i)$ 进行累加, 可得到一段电力线上的累计最小成本 $C(P_{t'_i}, P_{t'_{i+1}})$:

$$C(P_{t'_i}, P_{t'_{i+1}}) = \sum_{k=0}^{T_{P_{t'_i}, P_{t'_{i+1}}}} h(k) \quad (22)$$

其中, $T_{P_{t'_i}, P_{t'_{i+1}}}$ 表示 TLIR 执行完第 $P_{t'_i}$ 与第 $P_{t'_{i+1}}$ 个杆塔之间巡检任务所需的单一窗口数. 整个巡检周期覆盖所有电力线, 其目标是 minimized 巡检周期的累计时延和能耗, 即最小化 $\sum_{t'_i=t'_0}^{t'_{i+1}} C(P_{t'_i}, P_{t'_{i+1}})$, 最终的优化问题可用以下公式表示:

$$\begin{aligned} \text{P3: } & \arg \min_{\{P\}} \sum_{t'_i=t'_0}^{t'_{i+1}} C(P_{t'_i}, P_{t'_{i+1}}) \\ \text{s.t. } & \begin{cases} \text{C15: } P_{t'_{i+1}} \in V_{P_{t'_i}} \\ \text{C16: } E_{P_{t'_i}, P_{t'_{i+1}}}^{\text{visit}} \geq 1 \\ \text{C17: } \lim_{t'_i \rightarrow t'_n} E^{\text{visit}} = 0 \end{cases} \end{aligned} \quad (23)$$

其中, C15 表示 $P_{t'_{i+1}}$ 和 $P_{t'_i}$ 存在相邻边, $V_{P_{t'_i}}$ 为相邻边集合, C16 表示 $P_{t'_i}$ 和 $P_{t'_{i+1}}$ 间的电力线至少能被访问一次, C17 表示最终需要遍历完 E^* 中所有的边.

3 NGA-MOAO 算法设计

3.1 基于 Lyapunov 优化的问题转化

问题 P2 具有长期能耗上限约束 C13 和长期任务缓存队列稳态约束 C14, 如果 TLIR 的能耗过多, 或者队列负载过多, 将会导致 TLIR 的剩余能量不足, 或者缓存队列剩余容量不足. 从长远来看, 在没有全局信息的情况下, TLIR 难以对能耗和队列负载进行有效的管理. Lyapunov 优化的一个关键思想是在当前任务处理效率和约束管理之间取得最佳平衡^[29]. 通过 Lyapunov 优化, 本文能够将具有挑战性的长期多目标随机优化问题转换为单一窗口内的确定性问题进行求解. 为此, 本文针对约束 C13 构建一个长度为累计能耗的虚拟队列 $q(t_i)$:

$$\begin{aligned} q(t_i) = \max & \left\{ q(t_{i-1}) + E_{\text{loc}}(t_{i-1}) + E_{\text{tran}}(t_{i-1}) \right. \\ & \left. + E_{\text{move}}(t_{i-1}) - \frac{E_{\text{max}}}{t_{|T|}}, 0 \right\} \end{aligned} \quad (24)$$

其中, $E_{\text{max}}/t_{|T|}$ 表示单个单一窗口内可用的能量, $E_{\text{loc}}(t_{i-1}) + E_{\text{tran}}(t_{i-1}) + E_{\text{move}}(t_{i-1}) - E_{\text{max}}/t_{|T|}$ 表示在第 t_{i-1} 个单一窗口内 TLIR 消耗的能量与平均可用能量之间的偏差. 同样, TLIR 的任务缓存队列 $Q(t_i)$ 的推导公式(5)可以进行如下修改:

$$\begin{aligned} Q(t_i) = \max & \left\{ Q(t_{i-1}) - D_{\text{loc}}(t_{i-1}) - D_{\text{un}}(t_{i-1}) \right. \\ & \left. - \frac{Q_{\text{max}}}{t_{|T|}} + c(t_{i-1}), c(t_{i-1}) \right\} \end{aligned} \quad (25)$$

其中, $Q_{\text{max}}/t_{|T|}$ 表示单个单一窗口内可用的存储空间, $c(t_{i-1}) - D_{\text{loc}}(t_{i-1}) - D_{\text{un}}(t_{i-1}) - Q_{\text{max}}/t_{|T|}$ 表示在第 t_{i-1} 个单一窗口内任务缓存队列的实际计算量与平均可用存储空间之间的偏差. 由 $q(t_i)$ 和 $Q(t_i)$ 可定义 Lyapunov 函数如下:

$$L(\theta(t_i)) = \frac{1}{2} [q^2(t_i) + Q^2(t_i)] \quad (26)$$

其中, $\theta(t_i) = \{q(t_i), Q(t_i)\}$. 进一步定义相邻两个单一窗口之间的差值, 即 Lyapunov 漂移:

$$\Delta(\theta(t_i)) = [L(\theta(t_{i+1})) - L(\theta(t_i))] \theta(t_i) \quad (27)$$

Lyapunov 漂移加罚函数可以表示为

$$\Delta_{V_1}(\theta(t_i)) = \Delta(\theta(t_i)) + V_1 [T_{\text{total}} | \theta(t_i)] \quad (28)$$

$$\Delta_{V_2}(\theta(t_i)) = \Delta(\theta(t_i)) + V_2 [E_{\text{total}} | \theta(t_i)] \quad (29)$$

其中, 式(28)表示时延目标, 式(29)表示能耗目标, V_1 和 V_2 表示权衡因子, 用于衡量漂移与式(17)和式(18)目标函数之间的权重比. 通过最小化 $\Delta_{V_1}(\theta(t_i))$ 和 $\Delta_{V_2}(\theta(t_i))$, 可以实现最小化时延和能耗目标, 同时保持任务缓存队列和能耗虚拟队列的稳定性. 式(28)和式(29)的上界如下:

$$\begin{aligned} & [\Delta_{V_1}(\theta(t_i)), \Delta_{V_2}(\theta(t_i))] \\ & \leq B + [V_1 [T_{\text{total}} | \theta(t_i)], V_2 [E_{\text{total}} | \theta(t_i)]] \\ & + q(t_i) \left[E_{\text{loc}}(t_i) + E_{\text{tran}}(t_i) + E_{\text{move}}(t_i) - \frac{E_{\text{max}}}{t_{|T|}} | \theta(t_i) \right] \\ & + Q(t_i) \left[c(t_i) - D_{\text{loc}}(t_i) - D_{\text{un}}(t_i) - \frac{Q_{\text{max}}}{t_{|T|}} | \theta(t_i) \right] \end{aligned} \quad (30)$$

其中, B 是一个常数. 在权衡因子 V_1, V_2 的控制下, 系统长期平均目标值与最优值之间的偏差为 $O(1/V_{\text{max}})$, 对应的队列积压上界为 $O(V_{\text{max}})$. $V_{\text{max}} = \max(V_1, V_2)$ 表示整体调度强度参数. 因此, 原问题 P2 可以简化为没有长期约束的新问题 P4:

$$\begin{aligned} \text{P4: } & \arg \min_{\{A, U, F\}} \{V_1 T_{\text{total}}(t_i), V_2 E_{\text{total}}(t_i)\} \\ & + q(t_i) (E_{\text{loc}}(t_i) + E_{\text{tran}}(t_i) + E_{\text{move}}(t_i)) \\ & + Q(t_i) (c(t_i) - D_{\text{loc}}(t_i) - D_{\text{un}}(t_i)) \end{aligned} \quad (31)$$

s.t. C5~C12

此时, 每个单一窗口内的最少成本 $h(t_i)$ 的计算公式更改为

$$\begin{aligned} h(t_i) = & \eta (\lambda_1 \varphi_1 V_1 T_{\text{total}}(t_i) + \lambda_2 \varphi_2 V_2 E_{\text{total}}(t_i) \\ & + \varphi_3 q(t_i) (E_{\text{loc}}(t_i) + E_{\text{tran}}(t_i) + E_{\text{move}}(t_i)) \\ & + \varphi_4 Q(t_i) (c(t_i) - D_{\text{loc}}(t_i) - D_{\text{un}}(t_i))) \end{aligned} \quad (32)$$

其中, $\varphi_1 \sim \varphi_4$ 是归一化因子.

3.2 单一窗口多目标优化方法

问题 P4 隶属于单一窗口下的多目标多约束优化问题,考虑到其多目标和非线性特性,本文采用 SMNSGA-II 算法进行求解. 在 TLIR 巡检网络中, SMNSGA-II 将单一窗口内的任务卸载和资源分配优化方案编码为种群个体,其遗传结构包含多个决策变量,包括卸载决策、计算比例和计算频率,并通过快速非支配排序和遗传算子不断优化更新种群,使得变量朝着最小化目标函数的方向优化. 优化结果用于指导后续方案选择,以确保每一代种群的持续进步,具体的算法步骤如算法 1 所示.

算法 1 SMNSGA-II 算法

输入: 最大迭代次数 R , 种群规模 N , 交叉概率 q_c , 变异概率 q_m , 二进制交叉参数 η_c , 多项式变异参数 η_m , 可用 BS 集合 $M(t_i)$, 时隙任务缓存量 $Q(t_i)$, 时隙能耗积累量 $q(t_i)$

输出: 帕累托最优解集 H

1. 初始化 SMNSGA-II 参数
2. 生成初始化种群 p_1
3. $b_1 = \text{EvaluateObjectives}(p_1)$ // 根据式(31)计算 p_1 中个体的函数值
4. $L_1 = \text{EvaluateCV}(p_1)$ // 计算 p_1 中个体的违约值
5. $H = \text{FastNonDominatedSort}(p_1)$ // 快速非支配排序分层
6. $C_1 = \text{CrowdingDistance}(H)$ // 基于拥挤距离的层内排序
7. for $k = 1:R$ do
8. $K_k = \text{Selection}(p_k)$ // 选择
9. $K'_k = \text{CrossoverMutation}(K_k, q_c, \eta_c, q_m, \eta_m)$ // 交叉和变异
10. $b_k = \text{EvaluateObjectives}(K'_k)$
11. $L_k = \text{EvaluateCV}(K'_k)$
12. $R_k = p_k \cup K'_k$ // 合并父代种群和子代种群
13. $H = \text{FastNonDominatedSort}(R_k)$
14. $C_k = \text{CrowdingDistance}(H)$
15. $p_{k+1} = \text{CreateNextGeneration}(H, C_k, L_k, N)$ // 基于排序、拥挤距离和违约值选择下一代种群
16. end for
17. 返回帕累托最优解集 H

上述 SMNSGA-II 算法的基本框架中,快速非支配排序和拥挤距离计算部分沿用传统方法实现,本文对此不再赘述,其他步骤如下.

(1) 生成初始化种群. 本文中的个体是由整数型 0/1 变量(卸载决策)和实数型变量(计算比例和计算频率)组成的混合编码染色体. 由于 TLIR 具有高移动性,并非每个单一窗口都能被 BS 覆盖,因此在初始化种群时需要区分不同的情况. 当有 BS 覆盖时,染色体的基因结构为 $[A, U, F]$. 而在无 BS 覆盖时,染色体的基因结构简化为 $[\rho_{\text{loc}}(t_i), f_{\text{loc}}(t_i)]$. 与传统的变量约束不同,约束 (C5)~(C11) 对变量的范围进行了精确限制,确保每一个染色体都是可行解.

(2) 交叉和变异. 本文通过设定的概率 q_c 和 q_m 来控制染色体的交叉和变异操作. 对于整数型变量,本文采用单点交叉方式,确保交叉后的染色体满足系统约束,即每个染色体中只有一位为 1,其余为 0. 变异操作通过随机位翻转实现,每次变异仅改变一个基因位. 对于实数型变量,本文使用模拟二进制交叉(参数 η_c)^[30] 和多项式变异(参数 η_m)^[31] 进行处理.

(3) 个体违约值计算. 本文通过式(31)来评估每个染色体的函数值. 由于交叉和变异的操作,可能会出现一些染色体不满足约束 (C5)~(C11). 为此本文定义了一个变量 $L_{k,j}$, 表示第 k 个回合中第 j 个染色体违反约束的数值. $L_{k,j}$ 计算为

$$\begin{aligned} L_{k,j} &= l_1 + l_2 \\ &= \max(0, \rho_{\text{loc}}(t_i) + \rho_{\text{un}}(t_i) - 1) \\ &\quad + \max(0, T_{\text{BS}}(t_i) - (\Delta - T_{\text{tran}}(t_i))) \\ &\quad + \max(0, T_{\text{loc}}(t_i) - \Delta), \quad j = 1, 2, \dots, N \end{aligned} \quad (33)$$

其中, l_1 针对约束 (C7), 表示本地计算和 BS 计算比例之和超过 1 的惩罚. 此外,优化变量经过交叉和变异之后,可能存在任务量增多而计算频率不够的情况,会直接导致任务数据在一个单一窗口内未处理完就被丢弃. l_2 针对这种情况给出惩罚值,由任务实际处理时间减去任务规定处理时间(BS 侧为单一窗口长度减去传输时延)来表示.

通过 SMNSGA-II 算法求得每个单一窗口内的一组最优策略 H , 根据巡检系统对时延和能耗的不同需求,将相应加权系数代入式(32),从而计算出每个单一窗口内的最小成本 $h(t_i)$, 进而获得一段电力线上的累计最小成本 $C(P_{t_i}, P_{t_{i+1}})$. 值得注意的是,针对不同路径,即使在同一节点 P_{t_i} 作出同一路径选择 $P_{t_{i+1}}$, 成本 $C(P_{t_i}, P_{t_{i+1}})$ 也可能不同.

3.3 跨窗口联合优化策略

问题 P3 是一个结合复合窗口路径规划和单一窗口任务卸载与资源分配的跨窗口多目标优化问题. 为求解该问题,本文提出一种 NGA-MOAO 算法,通过基于单一窗口激励反馈的跨窗口联合优化策略对不同窗口下的优化变量进行解耦和联合优化. 单一窗口内通过 SMNSGA-II 算法动态优化卸载决策、计算比例和计算频率分配,以评估对应电力线上的任务处理成本,并将该成本转化为激励反馈值传入复合窗口,以指导路径选择并实现跨窗口优化. 鉴于路径规划的动作空间是离散的,复合窗口采用 D3QN 算法优化路径规划决策,该算法通过整合 Double Q-learning 方法和 Dueling Network 架构,能够有效改进传统 DQN 在价值估计偏差和状态泛化问题上的表现^[32].

将 TLIR 视为一个智能体,为优化智能体的决策过

程,本文在部署中引入强化学习策略.根据该策略,D3QN算法的3个核心要素^[33],即环境状态、动作空间和奖励定义如下.

(1)环境状态.路径规划基于复合窗口进行决策,时隙索引为 t'_i ,本文可以将任意索引 t'_i 处的系统状态定义为

$$s_{t'_i} = \{P_{t'_i}, \mathbf{E}^{\text{visit}}, Q(t'_i), q(t'_i)\} \quad (34)$$

其中, $P_{t'_i}$ 表示当前TLIR所处杆塔节点的索引值.考虑到单个数值难以神经网络提供足够的信息量,本文将 $P_{t'_i}$ 进行独热编码,转换成一个0和1向量. $\mathbf{E}^{\text{visit}}$ 是当前时隙每条边的访问次数矩阵.由于 $\mathbf{E}^{\text{visit}}$ 中的0元素较多,本文将 $\mathbf{E}^{\text{visit}}$ 转换成稀疏矩阵,对状态空间进行压缩. $Q(t'_i)$ 和 $q(t'_i)$ 分别表示任务缓存量和能耗积累量.

(2)动作空间.本文将每个复合窗口下的路径规划决策定义为一个动作,为确保动作空间的一致性,动作 $a_{t'_i}$ 定义为

$$a_{t'_i} = [a_{t'_i, v_1}, a_{t'_i, v_2}, \dots, a_{t'_i, v_{|V|}}] \quad (35)$$

其中, $a_{t'_i, v_j} \in \{0, 1\}$,当 $a_{t'_i, v_j} = 1$ 时,表示在第 t'_i 个复合窗口内选择第 v_j 个杆塔进行巡检.此时,系统状态的杆塔索引 $P_{t'_{i+1}} = v_j$,访问次数矩阵中的元素 $E_{P_{t'_i}, P_{t'_{i+1}}}^{\text{visit}} = E_{P_{t'_i}, P_{t'_{i+1}}}^{\text{visit}} - 1$,

表示该边的访问次数减少.值得注意的是,动作应当满足以下条件: $\sum_{v_j=v_1}^{v_{|V|}} a_{t'_i, v_j} = 1$.

(3)适应性奖励函数:本文定义奖励函数为杆塔之间累积成本的负值,即 $r = -C(P_{t'_i}, P_{t'_{i+1}})$.考虑到TLIR可能会进入死胡同(即当前节点的所有相邻边的可访问次数都为0)而提前结束巡检任务,本文增添了惩罚项,即 $-n_r r_2$.其中, n_r 表示未访问的边数.由访问次数矩阵中所有非零元素的值求和得到, r_2 表示每条边的惩罚系数.最终的适应性奖励函数 r ,即激励反馈值定义为

$$r = -C(P_{t'_i}, P_{t'_{i+1}}) - n_r r_2 \quad (36)$$

图3展示了NGA-MOAO的网络结构.在NGA-MOAO算法框架中有两个结构相同的神经网络:评估网络 Q^{eval} 和目标网络 Q^{tar} ,其参数向量分别是 θ 和 θ^- .经验缓存池D存储观察到的经验 $(s_{t'_i}, a_{t'_i}, r, s_{t'_{i+1}})$,通过随机采样的方式重用过去的经验,可以打破数据间的相关性.为保持一定的探索率,动作 $a_{t'_i}$ 会遵循以下探索规则:

$$\begin{cases} a_{t'_i, \text{rand}(v_1, v_{|V|})} = 1, & \text{if } b \leq \varepsilon \\ a_{t'_i} = \arg \max_{a_{t'_i}} Q(s_{t'_i}, a_{t'_i}; \theta), & \text{if } b > \varepsilon \end{cases} \quad (37)$$

其中, b 表示 $[0, 1]$ 之间的随机数, ε 表示按照一定规律递减的探索概率,计算公式如下:

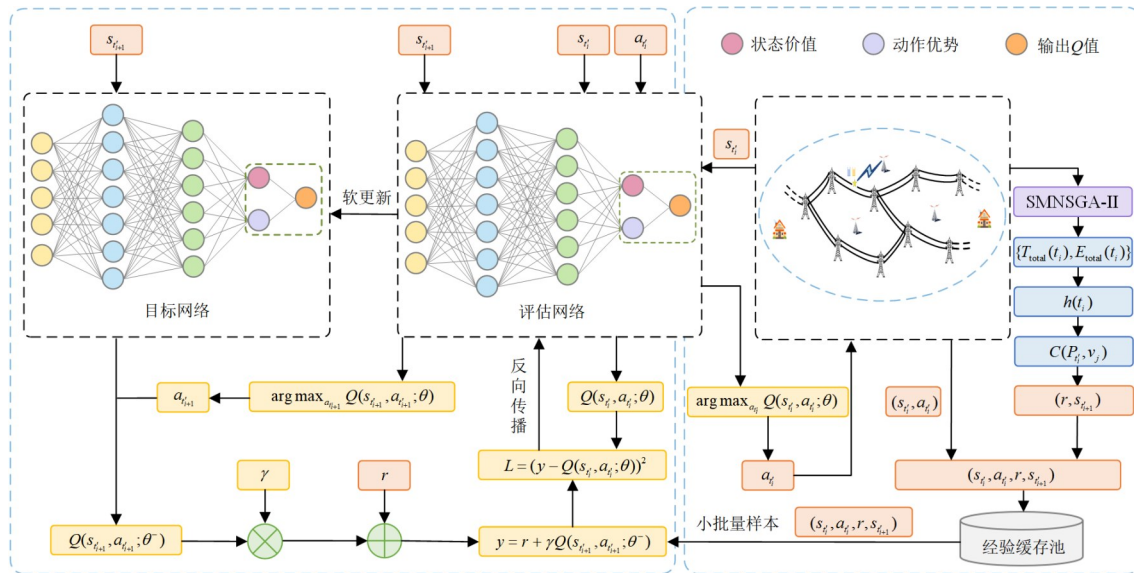


图3 NGA-MOAO网络结构图

$$\varepsilon = \varepsilon_{\max} + (\varepsilon_{\max} - \varepsilon_{\min}) e^{-\frac{1}{\varepsilon_{\text{decay}}} f_{\text{index}}} \quad (38)$$

其中, ε_{\max} 、 ε_{\min} 和 $\varepsilon_{\text{decay}}$ 分别表示 ε 的最终值、初始值和衰减参数, f_{index} 表示帧索引.当D中数据充足时,从中随机抽取 n_{bs} 个样本对神经网络进行训练, Q^{eval} 网络负责计算 $Q(s_{t'_i}, a_{t'_i}; \theta)$ 和选取状态 $s_{t'_{i+1}}$ 下的动作 $a_{t'_{i+1}} =$

$\arg \max_{a_{t'_{i+1}}} Q(s_{t'_{i+1}}, a_{t'_{i+1}}; \theta)$, Q^{tar} 网络负责计算动作 $a_{t'_{i+1}}$ 的 Q 值.进一步, Q^{eval} 网络基于如下损失函数 L 进行训练:

$$L = (y - Q(s_{t'_i}, a_{t'_i}; \theta))^2 \quad (39)$$

其中, y 可表示为

$$y = r + \gamma Q(s_{t'_{i+1}}, a_{t'_{i+1}}; \theta^-) \quad (40)$$

其中, γ 表示奖励折扣系数. 通过梯度下降法^[34]更新 Q^{val} 网络参数, 实现目标函数的最大化. 同时, 采用软更新的方式^[35]定时更新 Q^{tar} 网络参数 θ^- :

$$\theta^- = \omega\theta^- + (1 - \omega)\theta \quad (41)$$

其中, ω 表示更新幅度, 意味着参数 θ^- 会缓慢更新. NGA-MOAO 的训练过程见算法 2. 单一窗口内的时延和能耗通过 SMNSGA-II 优化获得, 根据式(32)线性加权得到单步成本 $h(t_i)$, 并在一段电力线上累积得到最小成本 $C(P_{t_i}, v_j)$, 进而将其转化成奖励 $r = -C(P_{t_i}, v_j)$. 若 TLIR 因进入死胡同而导致未完成全覆盖巡检任务, 则在最终奖励 r 中加入惩罚项 $-n_r r_2$, 以抑制不合理的路线选择. 最终, 算法在 D3QN 框架下更新网络参数实现收敛, TLIR 可根据训练给出的策略在线执行路径规划、任务卸载和资源分配.

算法 2 NGA-MOAO 算法

输入: 最大迭代次数 W 、小批量样本大小 n_{bs} 和探索率 ε

输出: 最优的路径规划决策、任务卸载决策、计算比例分配和计算频率分配

1. 初始化经验缓存池 D , 评价网络 Q^{val} 的参数 θ , 以及目标网络 Q^{tar} 的参数 $\theta^- = \theta$
2. for $l = 1: W$ do
3. 初始化状态 s_{t_i}
4. for $t'_i = t'_0: t'_{|T|}$ do
5. 根据概率 ε 选取当前状态对应的动作 $a_{t_i, v_j} = 1$
6. 通过 SMNSGA-II 求解对应的任务卸载和资源分配策略
7. 根据式(32)计算单一窗口内的最小成本 $h(t_i)$
8. 根据式(22)计算该段电力线上的累积成本 $C(P_{t_i}, v_j)$
9. 计算适应性奖励 $r = -C(P_{t_i}, v_j)$
10. if $\mathbf{E}^{\text{visit}}$ 中与杆塔 v_j 相邻节点的访问次数均为 0 then
11. 执行完当前轮次后巡检结束
12. else if $\mathbf{E}^{\text{visit}}$ 不为全 0 矩阵 then
13. 未实现全覆盖追加惩罚项 $r = -C(P_{t_i}, v_j) - n_r r_2$
14. end if
15. 将生成的经验 $(s_{t_i}, a_{t_i}, r, s_{t_{i+1}})$ 存储到 D 中
16. if D 中的样本足够 then
17. 从 D 中随机采样 n_{bs} 条样本 $(s_{t_i}, a_{t_i}, r, s_{t_{i+1}})$
18. 根据式(39)和式(40)更新 Q^{val} 网络参数 θ
19. 根据式(41)软更新 Q^{tar} 网络参数 θ^-
20. end if
21. end for
22. end for
23. 返回 $\{A, U, F, P\}$

4 模拟结果与讨论

4.1 模拟设置

为验证 NGA-MOAO 算法在 TLIR 巡检网络中的有

效性, 本文构建了基于 MEC-TLIR 的密集输电线路巡检仿真环境, 用以评估算法在接近真实场景下的性能. 在该仿真实验中, TLIR 巡检网络部署于一个 $600 \text{ m} \times 3000 \text{ m}$ 的区域, 其中包含 3 个 BS 和 19 个杆塔. 高压电力线在这些杆塔间交错连接, 总长度为 10 km . TLIR 安装在电力线上, 并以恒定的速度 v_r 沿线移动, 进行数据采集. 整个巡检周期被划分为 200 个时间长度为 14 s 的时隙, 其余参数设置详见表 1.

表 1 仿真参数

参数描述	值
滚动摩擦系数 C_r	0.005
风阻系数 C_d	0.7
TLIR 迎风面的投影面积 A_r	0.1904 m^2
交叉概率 q_c	0.9
变异概率 q_m	0.1
二进制交叉参数 η_c	20
多项式变异参数 η_m	18
计算一比特数据所需 CPU 周期数 s	737.5
截断区间 $[c(t_i)_{\min}, c(t_i)_{\max}]$	25~40 MB
TLIR 的 CPU 有效开关电容 κ_1	1×10^{-23}
BS 的 CPU 有效开关电容 κ_2	1×10^{-24}
TLIR 的发射功率 p	2 w
单位信道功率增益 α_0	-60 dBm
高斯白噪声 σ	-110 dBm
TLIR 的质量 m_r	4 kg
带宽 B_w	$2 \times 10^6 \text{ Hz}$
BS 信号覆盖范围 r_{BS}	500 m
任务缓存队列容量 Q_{max}	64 GB
TLIR 的电池容量 E_{max}	1 123 200 J
TLIR 的移动速度 v_r	5 m/s

为评估 NGA-MOAO 算法性能, 本文设计 3 种对比方案, 均以时延和能耗的线性加权作为统一优化目标, 并在此基础上采用不同机制进行优化, 具体如下.

对比方案 1: 人工智能赋能的多维协同优化算法^[15] (Artificial Intelligence-enabled Multi-Dimension Collaborative Optimization algorithm, AI-MDCO). 该算法在单一窗口内进行任务卸载优化, 并将结果作为反馈信号传递至复合窗口, 实现跨窗口的目标对齐. 为适配输电线路巡检场景, 任务卸载采用上置信界算法, 路径规划采用 Q-learning, 资源分配引入遗传算法 (Genetic Algorithm, GA) 进行处理, 并通过边访问标记与惩罚项设计确保全覆盖, 最终通过反馈机制实现跨窗口协同优化.

对比方案 2: 双时间尺度精度感知在线优化算法^[18] (Two-timescale Accuracy-aware Online Optimization algorithm, TAOO). 该算法通过分块坐标下降优化复合窗口变量, 并利用凸松弛方法优化单一窗口变量, 交替迭代

优化直至收敛. 为适配输电线路巡检场景, 在单一窗口内采用凸松弛方法求解任务卸载和资源分配, 在路径规划中引入高代价段重排序机制, 即选取连续高代价边段作为候选替换目标, 生成多条候选替代子路径并逐一评估成本, 若获得改进则更新路径, 直至整体成本收敛.

对比方案 3: 两阶段优化算法^[16] (Two-Stage Optimization algorithm, TSO). 该算法采用两阶段优化策略, 先在复合窗口内优化移动天线位置, 基于位置优化结果, 再利用最大比率传输优化波束向量. 为适配输电线路巡检场景, 在复合窗口中采用改进广度优先搜索 (Breadth-First Search, BFS) 生成覆盖所有线路的巡检路径, 并基于巡检路径在单一窗口中通过深度确定性策略梯度 (Deep Deterministic Policy Gradient, DDPG) 算法优化任务卸载和资源分配.

4.2 性能评估

图 4 展示了用于 TLIR 巡检网络的 NGA-MOAO 算法在不同学习率下巡检成本的收敛性能. 选择 $\alpha=0.01$ 和 $\alpha=0.001$ 进行对比, 可以在收敛速度和稳定性之间找到最佳平衡点, 较高的学习率 (如 0.1) 会导致模型的不稳定和振荡. 图 4 中每一回合表示一次巡检过程, 纵坐标表示巡检过程中的总成本; 平滑曲线表示巡检成本的滑动平均值, 用于平滑单次巡检结果的剧烈波动, 突出整体收敛趋势; 阴影区域则表示相应的滑动标准差范围, 越窄表明算法收敛越稳定. 可以观察到, 收敛过程大致分为 3 个阶段. 第一阶段, 成本波动明显, 这是因为 TLIR 处于网络探索期, 每次巡检的路径覆盖率不固定, 路径覆盖越少, 成本也越少. 第二阶段, 成本持续上升, 此时 TLIR 的探索率随着回合数的增加而降低, 开始更多地遵循算法给出的路径规划决策. 随着路径覆盖率的增加和神经网络对先验数据的不断学习, 系统的成本上升并趋于稳定. 第三阶段, 成本收敛, 路径规划逐渐实现全覆盖, 任务卸载和资源分配也得到了充分训练, 系统的成本开始收敛, 表明算法已达到稳定状态. 相较于 $\alpha=0.001$, $\alpha=0.01$ 的平滑曲线收敛更快、成本更低, 且阴影更窄更稳定. TLIR 在巡检过程中可能因进入死胡同而终止巡检, 导致全覆盖的巡检样本较




图 4 NGA-MOAO 在不同学习率下的收敛性能

少, 通过设置较高的学习率, 模型能更充分地利用有限样本加速收敛并降低巡检成本.

图 5 展示了各方案在不同杆塔数量下巡检成本、时延和能耗的对比, 各指标均随杆塔数量增加而上升. NGA-MOAO 表现最佳, 这是因为欧拉图的构建有效减少了移动能耗, 同时激励反馈引导路径规划为任务卸载创造更合理的时机, 从而在大规模场景下优势更加显著. AI-MDCO 虽然具有反馈机制, 但 Q-learning 结合访问标记的方式难以捕获路径分支, 易造成路径的重复访问. TACO 采用交替迭代在一定程度上实现跨窗口优化, 但候选路径的选择依赖启发式机制且凸松弛在多约束下易陷入次优. TSO 采用两阶段分层策略, 无法根据环境和实时负载动态调整卸载策略, 因此整体性能表现较差. 值得注意的是, 杆塔数量较少时性能差异主要源于单一窗口内的优化方法, 而数量增多后, 跨窗口联合优化的优势逐渐凸显, 同时多目标优化能在时延和能耗间实现权衡, 避免线性加权单一目标优化中可能出现的时延过低而能耗过高的失衡问题.

图 6 展示了各方案在不同加权系数占比 (时延比能耗) 下的性能对比, 其中加权系数按式 (32) 定义, 即成本由时延和能耗按比例线性加权得到. 从图 6(a) 可以看出, 随着加权系数的调整, 各方案的巡检成本均存在一定波动, 而 NGA-MOAO 曲线最为平稳且保持最低水平, 展现出较强的稳定性. 图 6(b) 和图 6(c) 也呈现了类似效果. 这是因为多目标优化会先生成一组帕累托非支配解, 再依据权重进行选择, 时延和能耗的波动幅度有限, 而线性加权的单一目标优化直接压缩成一个目标函数, 在权重偏向某一侧时可能极端牺牲另一指标, 因而曲线波动较大. 以 6:4 为例, NGA-MOAO 的巡检成本相较 AI-MDCO 降低 9.7%, 时延降低 10.3%, 能耗降低 18.1%, 进一步验证了所提方案在多目标权衡下的鲁棒性.

考虑到 TLIR 在巡检过程中可能因天气、植被等环境变化导致图像质量下降, 引起任务量激增. 本文设定激增任务量服从 40~50 MB 的截断正态分布, 激增持续时间服从 2~6 单一窗口的截断分布, 以模拟连续受影响的巡检阶段. 图 7 展示了各方案在不同任务激增次数下的性能对比. 相较于无激增, 当激增次数为 8 时, NGA-MOAO 成本增幅比 AI-MDCO、TACO 和 TSO 分别低 24.9%、29.7% 和 37.1%, 其原因在于 NGA-MOAO 通过构建欧拉回路避免冗余路径访问, 同时利用多目标优化在时延和能耗间保持平衡, 并结合激励反馈实现路径与卸载的联动优化, 从而能够在任务量突增的情况下动态创造出更合适的卸载时机.

图 8 展示了各方案在有/无欧拉图策略下巡检成本的对比 (选取最大杆塔数 29). 由图 8 可知, NGA-MOAO




图5 各方案在不同杆塔数量下的性能对比




图6 各方案在不同加权系数占比下的性能对比




图7 各方案在不同任务激增次数下的性能对比




图8 各方案在有/无欧拉图策略下巡检成本的对比

在无欧拉图时仍能有较好的表现,但由于缺乏对路径访问次数的限制,路径规划复杂性增加,其优化效果有

所下降. 其余方案在引入欧拉图构建后成本下降显著,凸显了欧拉图策略在复杂网络中的优化作用. 通过欧拉图策略,限制边的访问次数,构造最短欧拉回路,不但能满足全覆盖巡检要求,还可以使巡检总路程最短. 由于移动能耗远高于传输和计算能耗,减少冗余移动对于成本优化至关重要,因此有欧拉图构建的方案在巡检成本上具有显著优势. 而在无欧拉图构建时,缺乏对边访问次数的限制,强化学习和高代价阶段重排序往往会造成一些路径的重复访问,导致收敛困难.

BS 计算资源利用率可以衡量各算法的效率和系统稳定性. 图9展示了各方案在不同最大计算频率下BS 计算资源利用率的对比. 可以观察到,所有方案的资源利用率均随着计算频率的增加而降低,这是因为当计




图9 各方案在不同最大计算频率下BS计算资源利用率对比

算资源有限时,系统需要充分利用资源来保持队列稳定,而在计算资源增加后,需更多关注成本优化,资源利用率相应有所下降。TSO因采用两阶段分离方式,无法及时通过路径规划调整卸载策略,其资源利用率下降显著。相比之下,NGA-MOAO凭借其激励反馈机制,能够在巡检过程中通过动态调整路径规划适应队列和任务变化,及时有效地优化任务卸载与资源分配,实现计算资源的高效利用。此外,由于本地计算能耗通常高于传输和BS计算的总能耗,将更多任务卸载至BS可实现更低的系统能耗。

当TLIR的任务负载和能耗较大时,选择适当的卸载时机对于控制巡检成本至关重要。图10展示了TLIR在一定负载量和能耗条件下,不同巡检路径对巡检成本的影响。蓝色箭头表示联合优化方案下的路径,绿色箭头表示两阶段方案下的路径。可以看到,蓝色路径在早期就进行卸载,这样能够有效稳定任务缓存队列,使得TLIR以较低的任务缓存量进入无BS覆盖区域,减少后续的处理压力,降低整体巡检成本。相比之下,绿色路径的卸载时间更靠后,虽然在早期阶段的成本较低,但未能及时进行任务卸载,导致任务缓存队列在无BS覆盖线路上持续累积。经过Lyapunov转化的模型中,队列缓存量会计入成本,因此较高的任务缓存量会导致

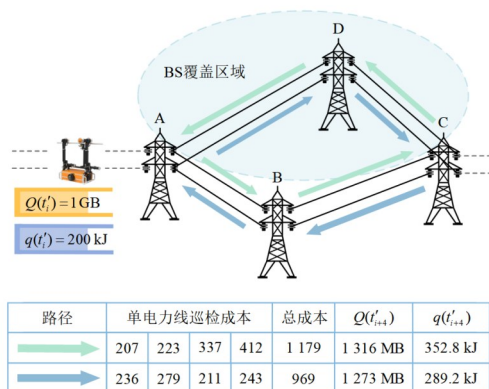


图10 不同巡检路径对成本的影响

整体成本大大增加。实验结果表明,联合优化方案展现了显著的成本优势,而两阶段卸载方案在无BS覆盖区域内的巡检成本更高。

5 结论

针对基于MEC-TLIR的密集输电线路巡检场景,本文提出了一种基于粒度嵌套的多目标输电线路巡检卸载策略,以最小化系统能耗和时延。该策略采用欧拉图构建最短欧拉回路实现全覆盖式巡检,同时设计任务缓存与能耗虚拟双队列机制,结合Lyapunov优化将长期约束转化到间隙级优化,从而管理任务积压与能耗。为此,本文设计了一种粒度嵌套感知的多目标自适应卸载算法NGA-MOAO,在粒度嵌套结构中通过单一窗口激励反馈复合窗口的跨窗口方式,实现路径规划、任务卸载和资源分配的联合优化。仿真结果表明,NGA-MOAO相较于两阶段方案,显著降低了巡检成本、时延与能耗,并提高资源利用率。该跨窗口联合优化方式对于解决带有时序差异性决策问题具有借鉴意义。未来将进一步研究多TLIR多BS协同巡检场景下的联合优化问题,包括任务卸载、资源分配、路径规划和单一窗口调度优先级等,以优化其在通信干扰环境中的自适应能力。

参考文献

- [1] HOSSAIN E, ROY S, MOHAMMAD N, et al. Metrics and enhancement strategies for grid resilience and reliability during natural disasters[J]. Applied Energy, 2021, 290: 116709.
- [2] CHEN M H, CAO Y H, TIAN Y N, et al. A passive compliance obstacle-crossing robot for power line inspection and maintenance[J]. IEEE Robotics and Automation Letters, 2023, 8(5): 2772-2779.
- [3] ZHAO T, LIU J H, DIAN S Y, et al. Sliding-mode-control-theory-based adaptive general type-2 fuzzy neural network control for power-line inspection robots[J]. Neurocomputing, 2020, 401: 281-294.
- [4] LIU Z Y, WU G P, HE W S, et al. Key target and defect detection of high-voltage power transmission lines with deep learning[J]. International Journal of Electrical Power & Energy Systems, 2022, 142: 108277.
- [5] YANG L, FAN J F, LIU Y H, et al. A review on state-of-the-art power line inspection techniques[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(12): 9350-9365.
- [6] 陈阳, 皮德常, 代成龙, 等. 多无人机协同陆地设施辅助移动边缘计算的系统能耗最小化方法[J]. 电子学报, 2023, 51(4): 984-992.

- CHEN Y, PI D C, DAI C L, et al. Energy minimization for multi-UAVs cooperative ground access points assisted mobile edge computing[J]. *Acta Electronica Sinica*, 2023, 51(4): 984-992. (in Chinese)
- [7] XIA J M, LIU Y F, TAN L. Joint optimization of trajectory and task offloading for cellular-connected multi-UAV mobile edge computing[J]. *Chinese Journal of Electronics*, 2024, 33(3): 823-832.
- [8] 谈玲, 许海, 刘玉凤, 等. 基于多无人机的空中计算网络资源分配算法[J]. *电子学报*, 2023, 51(11): 3070-3078.
- TAN L, XU H, LIU Y F, et al. Resource allocation algorithm of AirComp network based on multiple UAVs[J]. *Acta Electronica Sinica*, 2023, 51(11): 3070-3078. (in Chinese)
- [9] ZHANG H X, YANG Y J, SHANG B D, et al. Joint resource allocation and multi-part collaborative task offloading in MEC systems[J]. *IEEE Transactions on Vehicular Technology*, 2022, 71(8): 8877-8890.
- [10] ABBAS N, FAWAZ W, SHARAFEDDINE S, et al. SVM-based task admission control and computation offloading using Lyapunov optimization in heterogeneous MEC network[J]. *IEEE Transactions on Network and Service Management*, 2022, 19(3): 3121-3135.
- [11] SHAO S J, LI Y, GUO S Y, et al. Delay and energy consumption oriented UAV inspection business collaboration computing mechanism in edge computing based electric power IoT[J]. *Chinese Journal of Electronics*, 2023, 32(1): 13-25.
- [12] SHEN H, JIANG Y J, DENG F M, et al. Task unloading strategy of multi UAV for transmission line inspection based on deep reinforcement learning[J]. *Electronics*, 2022, 11(14): 2188.
- [13] ZHANG Y, LI J F, ZHANG L T, et al. Energy consumption optimal design of power grid inspection trajectory for UAV mobile edge computing node[C]//2021 6th Asia Conference on Power and Electrical Engineering. Piscataway: IEEE, 2021: 1316-1321.
- [14] ZHOU Z Y, ZHANG C T, XU C, et al. Energy-efficient industrial Internet of UAVs for power line inspection in smart grid[J]. *IEEE Transactions on Industrial Informatics*, 2018, 14(6): 2705-2714.
- [15] WANG W, QU R, LIAO H J, et al. 5G MEC-based intelligent computation offloading in power robotic inspection[J]. *IEEE Wireless Communications*, 2023, 30(2): 66-74.
- [16] ZHENG Z, WU Q, CHEN W, et al. Two-timescale design for movable antenna-enabled multiuser MIMO systems[EB/OL]. (2024-10-08)[2025-08-26]. <https://arXiv.org/abs/2410.05912v1>.
- [17] LIU W S, FU Y R, GUO Y N, et al. Two-timescale synchronization and migration for digital twin networks: A multi-agent deep reinforcement learning approach[J]. *IEEE Transactions on Wireless Communications*, 2024, 23(11): 17294-17309.
- [18] YANG Y Y, SHI Y, YI C Y, et al. Dynamic human digital twin deployment at the edge for task execution: A two-timescale accuracy-aware online optimization[J]. *IEEE Transactions on Mobile Computing*, 2024, 23(12): 12262-12279.
- [19] FENG B Q, FENG C Y, MIN G Y, et al. Two-timescale adaptive live video streaming transmission mechanism for vehicular networks[J]. *IEEE Transactions on Vehicular Technology*, 2025, 74(4): 6823-6828.
- [20] ZHAO J H, CHEN M, PAN Y J, et al. Energy minimization of the cell-free MEC networks with two-timescale resource allocation[J]. *IEEE Transactions on Wireless Communications*, 2024, 23(12): 18623-18636.
- [21] ZHAO Y K, ZHOU F Q, FENG L, et al. Joint deployment and resource allocation for multi-AeBS networks: A two-timescale optimization framework using MADRL[J]. *IEEE Transactions on Communications*, 2025, 73(6): 4272-4289.
- [22] WANG Y F, ZHAO L Q, CHU X L, et al. Two-timescale optimization for E2E network slicing-aided cloud-edge collaborative networks[J]. *IEEE Transactions on Vehicular Technology*, 2025, 74(6): 9777-9789.
- [23] BANSAL G, CHAMOLA V, ANSARI N, et al. Scalable topologies for time-optimal authentication of UAV swarms[J]. *IEEE Network*, 2022, 36(6): 126-132.
- [24] LV C J, ZHANG L, LI X Y. Personalized differentially private online minimum bipartite matching in spatial crowdsourcing[C]//2022 8th International Conference on Big Data Computing and Communications. Piscataway: IEEE, 2023: 134-143.
- [25] CHEN Y, ZHAO F J, LU Y G, et al. Dynamic task offloading for mobile edge computing with hybrid energy supply[J]. *Tsinghua Science and Technology*, 2023, 28(3): 421-432.
- [26] SUN Z M, SUN G, LIU Y H, et al. BARGAIN-MATCH: A game theoretical approach for resource allocation and task offloading in vehicular edge computing networks[J]. *IEEE Transactions on Mobile Computing*, 2024, 23(2): 1655-1673.

- [27] ZHU B C, CHI K K, LIU J J, et al. Efficient offloading for minimizing task computation delay of NOMA-based multiaccess edge computing[J]. IEEE Transactions on Communications, 2022, 70(5): 3186-3203.
- [28] LU H Q, ZENG Y, JIN S, et al. Aerial intelligent reflecting surface: Joint placement and passive beamforming design with 3D beam flattening[J]. IEEE Transactions on Wireless Communications, 2021, 20(7): 4128-4143.
- [29] JIA Y, ZHANG C, HUANG Y M, et al. Lyapunov optimization based mobile edge computing for Internet of vehicles systems[J]. IEEE Transactions on Communications, 2022, 70(11): 7418-7433.
- [30] ABOUHAWWASH M, ALESSIO A M. Multi-objective evolutionary algorithm for PET image reconstruction: Concept[J]. IEEE Transactions on Medical Imaging, 2021, 40(8): 2142-2151.
- [31] LIU Y C, TANG L X, DING J L, et al. A dual mutation-based evolutionary algorithm for dynamic multiobjective optimization with undetectable changes[J]. IEEE Transactions on Evolutionary Computation, 2025, 29(4): 1199-1214.
- [32] HAO J K, JIN M, BAI H Y, et al. Heterogeneous resource scheduling in computing power networks: A method based on improved D3QN[C]//2024 IEEE 6th Advanced Information Management, Communicates, Electronic and Automation Control Conference. Piscataway: IEEE, 2024: 1561-1567.
- [33] WANG Z C, WANG R, WU J, et al. Dynamic resource allocation for real-time cloud XR video transmission: A reinforcement learning approach[J]. IEEE Transactions on Cognitive Communications and Networking, 2024, 10(3): 996-1010.
- [34] ZHANG H C, HAO K R, GAO L, et al. Optimizing deep neural networks through neuroevolution with stochastic gradient descent[J]. IEEE Transactions on Cognitive and Developmental Systems, 2023, 15(1): 111-121.
- [35] HU H, WU D G, ZHOU F H, et al. Intelligent resource allocation for edge-cloud collaborative networks: A hybrid DDPG-D3QN approach[J]. IEEE Transactions on Vehicular Technology, 2023, 72(8): 10696-10709.

作者简介



谈玲 女, 1979年6月出生于江苏省宜兴市. 现为南京信息工程大学计算机学院教授、博士生导师. 研究方向为数据处理、边缘计算.
E-mail: cillatan0@nuist.edu.cn



姚永雷 男, 1976年9月出生于山东省济宁市. 现为南京信息工程大学计算机学院副教授、硕士生导师. 主要研究方向为移动计算、普适计算和隐私保护.
E-mail: ylyao@nuist.edu.cn



汪海峰 男, 1999年3月出生于浙江省杭州市. 现为南京信息工程大学计算机学院在读硕士生. 主要研究方向为电网巡检和移动边缘计算.
E-mail: 202312490585@nuist.edu.cn



许海 男, 1998年6月出生于江苏省泰州市. 现为南京信息工程大学计算机学院在读硕士生. 主要研究方向为无人机和智能反射面辅助边缘计算. 中国电子学会会员编号: E190016078M.
E-mail: 202212490302@nuist.edu.cn



宋静 女, 2001年3月出生于江苏省连云港市. 现为南京信息工程大学计算机学院在读硕士生. 主要研究方向为反向散射和边缘计算.
E-mail: 202312490551@nuist.edu.cn