

# 电网碳强度感知的数据中心电算协同任务调度方法

王梓屹<sup>1</sup>, 郭少勇<sup>1</sup>, 陈洁蔚<sup>1</sup>, 肖轶涛<sup>1</sup>, 蔡田田<sup>2</sup>, 张子昊<sup>2</sup>, 亓峰<sup>1</sup>

(1. 网络与交换技术国家重点实验室 (北京邮电大学), 北京市 100876; 2. 南方电网数字电网研究院股份有限公司, 广州 510700)

**摘要:** 人工智能潮流下, 数据中心用能规模持续增长, 为缓解计算任务服务质量保障需求与新能源供电波动之间的矛盾, 本文研究了一种电网碳强度感知的数据中心电算协同任务调度方法。首先, 提出电网碳强度感知的地理异构数据中心任务调度框架, 描述电力侧碳排放属性对算力侧任务分配的影响。其次, 针对工作流任务拓扑依赖, 异构算力资源以及电网碳强度的时空耦合特性, 提出 GINEConv-PPO 智能调度机制, 通过先验时间规划算法提取任务关键链位置与资源竞争风险, 构建时间优先级特征, 并基于考虑边特征的图同构网络, 设计图感知增强的近端策略优化算法, 以实现服务质量约束下的低碳任务分配。仿真结果表明, GINEConv-PPO 能够满足作业批次截止时间约束, 以同一场景下各算法取得的最低碳排放量为基准, 面对不同类型和规模的工作流场景时, 所提方法的碳排放量相对偏差保持在 0% 附近, 其余各基准算法的碳排放量相对偏差最低约为 6%, 最高约为 35%, 实现了服务质量保障下的低碳调度目标。

**关键词:** 电算协同; 任务调度; 碳排放; 深度强化学习

**中图分类号:** TP393

**文献标志码:** A

**doi:** 10.11959/j.issn.1000

## Grid Carbon-Intensity-Aware Power-Computing Coordinated Task Scheduling for Data Centers

WANG Ziyi<sup>1</sup>, GUO Shaoyong<sup>1</sup>, CHEN Jiewei<sup>1</sup>, XIAO Yitao<sup>1</sup>, CAI Tiantian<sup>2</sup>, ZHANG Zihao<sup>2</sup>, QI Feng<sup>1</sup>

1. State Key Laboratory of Networking and Switching Technology (Beijing University of Posts and Telecommunications), Beijing 100876, China

2. Digital Grid Research Institute of China Southern Power Grid, Guangzhou 510700, China

**Abstract:** With the rapid growth of AI, data-center energy consumption continues to increase. To balance computing service requirements and renewable-energy fluctuations, a grid carbon-intensity-aware power-computing coordinated scheduling method was proposed. First, a scheduling framework for geographically distributed heterogeneous data centers was developed to characterize how carbon emission attributes on the power supply side influence task allocation on the computing side. Then, considering workflow dependencies, heterogeneous resources, and spatiotemporal variations in grid carbon intensity, a GINEConv-PPO scheduling mechanism was proposed. A temporal planning algorithm extracted critical-chain positions and resource-contention risks to construct temporal-priority features, while GINEConv was integrated with PPO for low-carbon task allocation under QoS constraints. Simulations across workflow types and sizes showed that GINEConv-PPO met job-batch deadlines. Relative to the lowest emissions achieved by the compared algorithms in each scenario, its emission deviation remained near 0%, versus approximately 6%–35% for the baselines.

**Key words:** Power-Computing co-scheduling, task scheduling, carbon emissions, Deep Reinforcement Learning

收稿日期: XXXX-XX-XX; 修回日期: XXXX-XX-XX

通信作者: 郭少勇, syguo@bupt.edu.cn

基金项目: 智能电网重大专项(2030)资助(2025ZD0804700)

**Foundation Items:** This work is supported by Smart-Grid National Science and Technology Major Project(2025ZD0804700)

## 0 引言

随着以大模型为代表的人工智能技术高速发展,算力需求持续攀升,致使以数据中心为核心的算力基础设施规模不断扩张。这种扩张不可避免地导致了算力系统用能规模的急剧攀升。2023 年全国数据中心总耗电量 1500 亿千瓦时, 占全社会用电 1.6%, 碳排放总量 0.84 亿吨<sup>[1]</sup>。预计到 2030 年全国数据中心的总电力消耗将达到 3800 亿千瓦时<sup>[2]</sup>。巨大能源消耗与高昂的电力成本, 逐步成为制约数据中心运营的瓶颈。近年来, 我国陆续出台新型数据中心等算力基础设施的绿色低碳发展相关政策, 强调提升算力基础设施能效水平和新能源电力利用比例<sup>[3-4]</sup>。

在此背景下, 数据中心低碳运行不再仅是降低总用电量, 还需要提升算力负荷对本地新能源供给的匹配能力, 使计算任务尽可能在低碳电力充足的时段和区域执行, 从而减少实际用电碳排放。

然而以风能和太阳能为主的清洁新能源在时间和空间维度上都呈现出显著的随机波动特性和资源分布差异<sup>[5]</sup>。此外, 数据中心承载的计算任务对处理时效性有着严苛的服务质量标准, 要求电力的长期稳定供应。这种服务需求的高确定性要求与新能源供给侧的强波动性之间构成了显著的矛盾<sup>[6]</sup>。若仍采用传统固定负载运行方式, 数据中心为保障计算服务连续性往往需要依赖高可靠性的常规电力供应, 导致本地低碳电力利用不足。因此, 如何在保障计算任务服务质量的前提下, 引导算力负荷主动匹配本地新能源出力和区域电网低碳时段, 成为实现数据中心绿色运行的核心问题。面对这种供需两端的结构性矛盾, 我国提出了电算协同这一极具潜力的科学解决路径。

电算协同, 就是指打破传统数据中心作为静态负载的局限, 利用计算任务可以在时间与空间上迁移的灵活特性, 构建以“算力服务-任务属性-算力资源-电力供应”为核心纽带, 实现电算双向互动和全局优化的新型基础设施体系<sup>[7]</sup>。在此思想下, 算力侧可以通过规划与调度计算任务, 引导具有时间灵活性的算力负荷主动匹配电力侧的电力市场信号或新能源发电信号, 使其由传统的静态负荷转变为具备时空可调节潜力的优质需求侧资源<sup>[8]</sup>。

然而, 在广域分布的异构算力集群中实现电算协同调度仍面临多重挑战。首先, 跨域数据中心内

部服务器等算力资源在计算频率、能耗特性、内存容量和网络带宽等方面存在显著异构性<sup>[9]</sup>。其次, 数据中心承载的计算任务往往以 workflow 形式存在, 任务之间具有复杂的有向无环图依赖关系, 任一关键路径任务的延迟都可能向后传播并放大为整体完工时间增加<sup>[10]</sup>。此外, 不同区域电网的新能源出力不同, 导致各区域电网碳强度随时间动态变化, 且低碳区域并不总是与高算力资源区域重合, 将任务迁移至低碳数据中心虽然可能降低单位能耗碳排放, 但也可能引入跨域通信开销、资源竞争和排队延迟, 进而影响服务质量<sup>[11]</sup>。因此, 电算协同调度并不是单纯的算力资源分配问题, 而是同时耦合任务拓扑、异构资源、跨域网络和电网碳强度时空波动的多目标联合优化问题。随着 workflow 数量、任务规模和候选算力节点数量增加, 任务排序与资源匹配组合呈指数级增长, 该问题在数学本质上具有典型的 NP 难特征<sup>[12]</sup>, 传统优化方法难以在调度所需时间内获得高质量全局决策。

针对数据中心任务调度问题, 传统方法采用动态规划等方法进行建模求解<sup>[13]</sup>。然而, 精确优化方法在面对多 workflow、多数据中心和动态电力环境时扩展性不足, 难以在给定时限内完成精确求解<sup>[14-15]</sup>。近年来, 强化学习方法为求解复杂 NP 难调度问题提供了新的思路, 部分研究已将深度强化学习用于云计算任务调度, 并进一步结合图神经网络提取有向无环图 (directed acyclic graph, DAG) 任务依赖特征<sup>[16-17]</sup>。但现有方法大多仍以完工时间、资源利用率、能耗或电力成本为主要优化目标, 对电力侧供给属性的刻画不足, 尤其缺乏对区域电网新能源供给波动以及任务迁移碳排后果的联合建模, 难以体现电算协同场景下“计算任务—算力资源—电力供给”之间的时空耦合关系。

为此, 本文提出了一种电网碳强度感知的数据中心电算协同调度方法, 对多 workflow 作业批次中的任务在地理分布式数据中心服务器间进行调度, 在满足作业批次截止时间的条件下最大限度地利用多区域电网交错的较低碳时间间隔, 从而降低任务执行总碳排放量。本文的主要贡献如下:

- 1、提出了一种电网碳强度感知的地理异构数据中心任务调度框架, 通过综合考虑 workflow 完工时间、碳排放、workflow 拓扑依赖和异构算力资源等约束, 构建多目标成本优化模型, 为实现电网碳强度

感知的跨域任务调度提供数学模型基础。

2、提出了 GINEConv-PPO 智能调度机制,针对 workflow 任务拓扑依赖,地理分布式数据中心资源以及电网碳强度的时空耦合特性,使用考虑边特征的图同构网络 (graph isomorphism network convolution with edge features, GINEConv) 赋予近端策略优化算法 (proximal policy optimization, PPO) 全局图感知的能力,实现在高频碳强度时空波动环境下对复杂多 workflow 作业批次进行自适应任务调度决策。

3、设计了一种先验时间规划算法,为 workflow 中每个任务生成符合任务特性的先验时间优先级,并作为状态特征辅助强化学习智能体感知关键链任务和资源竞争风险,从而提升强化学习智能体的搜索效率与约束满足能力。

4、大量基于真实电网时序数据的仿真实验验证了本文调度机制的有效性。实验结果表明,GINEConv-PPO 能够满足作业批次截止时间约束,以同一场景下各算法取得的最低碳排放量为基准,所提方法的碳排放量相对偏差保持在 0% 附近,其余各基准算法的碳排放量相对偏差最低约为 6%,最高约为 35%。

## 1 相关工作

现有电算协同研究已逐步形成从协同机制设计到调度策略实现的研究路线。其中,协同机制研究重点关注电力系统与算力系统的交互模式,而任务调度研究则聚焦于协同目标的具体实现。为此,本节分别对上述两方面研究进展进行概述。

### 1.1 电算协同机制

在智算需求爆发式增长的时代背景下,以地理分布式数据中心为核心的算力基础设施,现已逐步演变为电力系统中体量庞大、影响关键的巨型负荷节点。为破除传统能源系统与信息计算系统彼此割裂的孤岛状态,近年来学术界与工业界致力于构建一套具备物理实体融合、信息可交互特征的新一代综合基础设施体系,电算协同运行机制应运而生,并正在经历一场从单向被动响应到双向深度耦合的深刻演进。

在早期的理论研究与工程实践中,电力市场驱动机制是实现电算协同最基础、应用最广泛的调控方案<sup>[18]</sup>。在此范式下,电网并不直接干预计算系

统的运行,而是通过节点边际电价或实时电价等市场化工具,向算力系统隐式传递底层电力网络的供需紧张程度与空间拥塞状况<sup>[19]</sup>。同时,也有研究者探索了算力负荷参与电力市场的具体路径<sup>[20]</sup>。如文献[21]提出了一种基于分层强化学习的多时间尺度决策方法,使数据中心能够同时参与频率调节和备用服务市场。

然而,高比例风光新能源并网后,电价机制信号滞后、易造成算力集聚诱发电网阻塞。在此背景下,需求响应协同机制逐渐跃升为学术界关注的焦点<sup>[22]</sup>。研究者开始在理论建模中将数据中心重塑为电网中极具灵活性、高可靠性且响应极速的柔性负荷<sup>[23]</sup>。当电网面临紧急容量缺口或频率失稳的严峻挑战时,调度中心可通过下发明确的削峰指令或容量邀约信号,促使算力系统通过复杂的内部资源编排机制——如任务排队延迟、底层计算单元降频运行乃至主动牺牲边缘请求的服务质量 (QoS),以实现毫秒级别的精确负荷削减,直接为物理电网提供强有力的稳定性支撑<sup>[24-25]</sup>。

随着地理分布式数据中心规模的持续扩张,单独的数据中心节点已难以在庞大的电力市场中发挥调节作用。虚拟电厂机制通过聚合技术,将海量分布的算力资源转化为电网中高度可控的超级调节实体<sup>[26]</sup>。

综上,近年来研究人员提出了多种包括需求响应、实时电价引导以及虚拟电厂聚合等电算协同的机制,通过提升数据中心负荷灵活性实现电网与算力系统协同运行。然而,上述工作主要关注协同框架构建或经济激励设计,缺乏对任务级资源调度过程的深入建模,难以充分释放跨域算力迁移潜力。

### 1.2 电算协同任务调度方法

另一方面的研究则从计算任务调度的角度探索电算协同的具体实现路径,通过动态调整任务的时间分布、空间分布及资源分配方式,实现特定的算力网络服务目标。近年来,针对复杂 workflow 的多目标调度,研究者提出了多种混合元启发式方法。例如,文献[27]提出的 HEFT 算法根据任务的平均计算与通信成本确定优先级,并将任务分配至能够最早完成任务的异构处理器;MOHEFT 在此基础上维护多目标候选解集,以同时权衡工期和成本等目标<sup>[28]</sup>。此类基于固定规则的方法在线计算开销较低,但对多数据中心动态环境的适应能力有限。为

扩大组合空间中的搜索范围,文献[15]使用两阶段多种群遗传算法,通过启发式初始化和种群协同改善异构环境中的工作流调度质量;文献[29]提出动态分组学习分布式粒子群优化算法,以提高大规模云工作流调度问题的搜索能力;文献[30]通过变异机制和种群分组改进局部强化优化算法,用于求解预算约束下的工作流调度问题;文献[31]则采用多种群协同进化的蚁群系统,在云工作流调度中联合优化执行时间和执行成本;文献[32]进一步提出聚类辅助的梯度优化算法,以改善预算约束下并行工作流的任务与资源的映射效果。这些方法表明,元启发式算法能够处理多工作流、多目标和资源约束条件,弥补传统方法在解决 NP 难问题上的不足<sup>[33-34]</sup>,但是不同数据中心计算节点的资源具有时空动态属性,采用启发式算法容易引发寻优过程中陷入局部最优的问题。且固定优先规则或重复种群搜索难以在多工作流并发场景中同时感知区域电网碳强度变化、跨域通信代价和异构资源竞争,也难以评估当前任务与资源的匹配对后续调度空间的长期影响。强化学习(reinforcement learning, RL)的发展为动态任务调度提供了新的解决思路。文献[35]提出了多种 RL 算法,以最小化任务执行时间为目的进行任务调度,文献[36]则利用加权双深度 Q 网络(Weighted double deep Q-network, WD-DQN)处理云环境中的双目标多工作流调度问题,在任务工期与执行成本之间进行权衡。

然而,上述研究大多没有考虑跨地域的多个计算节点的供电系统特征。为解决这一问题,文献[37-38]通过任务分配、动态电压和频率调整等技术来减少能源消耗以及电力成本,但这些研究主要关注独立的任务,仍然没有考虑工作流中的依赖关系。文献[39]利用图神经网络,尝试在满足 DAG 依赖约束的前提下优化数据中心的电力成本;文献[40]使用深度强化学习算法完成单数据中心内的低碳调度;文献[41-43]则利用图同构网络或双向图卷积网络提取拓扑特征,优化异构环境中的任务完工时间或资源利用率。然而,这些研究多局限于单数据中心内部的时间调度或计算效率优化,忽略了地理分布式场景下算力资源与新能源供电的时空耦合,难以实现系统级低碳协同。

综上所述,虽然目前的研究已经对任务调度的能耗问题进行了广泛的研究,但是,由于分布式数

据中心所处区域的新能源发电波动性和任务依赖复杂性,使得以降低任务执行总碳排放量为目标的调度演变为一个电算时空耦合的联合优化难题,这比单纯的能耗最小化问题更具有挑战性。但现有研究要么未能充分聚焦于对具有复杂内部依赖关系的独立工作流进行细粒度空间编排,要么将优化目标局限于减少物理能源的绝对消耗总量而非实际产生的碳排放量,针对具备高维特征感知与动态碳驱动特征的调度算法研究目前仍处于起步阶段。

## 2 场景描述及系统建模

图1展示了电算协同场景下新能源与传统能源混合供电的地理分布式数据中心任务调度架构。用户提交的工作流任务首先进入跨域算力调度系统,调度系统综合感知各数据中心的算力资源状态以及所在区域电网的供电情况,将任务动态分配至不同地理区域的数据中心执行。本文利用区域间新能源供给差异,引导算力负荷向低碳区域迁移,实现电算协同下算力任务低碳执行的目标。




图1 电算协同场景下跨域任务调度框架示意图

### 2.1 数据中心模型

本文所研究的电算协同系统的调度场景由  $N$  个地理分布的异构数据中心构成,其集合表示为  $D = \{D_1, \dots, D_N\}$ , 每个数据中心  $D_k$  内部署了  $\omega_k$  台物理服务器,其集合为  $S = \{S_1^k, \dots, S_{\omega_k}^k\}$ 。因此,系统中的任意一台物理服务器  $S_l^k$  均可通过一个唯一的二元组索引  $(k, l)$  来标识,代表位于数据中心  $D_k$  中的第  $l$  台服务器。为对异构的算力资源进行统一建模,将所有服务器节点及其网络连接关系抽象为一个有

向无环图  $G_d = (V_d, E_d)$ 。其中, 节点集  $V_d$  代表数据中心内所有物理服务器的集合。每个服务器节点  $S_l^k$  都具备一组特征用以刻画其计算能力、内存容量及能耗特性。边集  $E_d$  代表服务器间的物理网络连接。

## 2.2 计算任务模型

用户提交的计算任务以工作流的形式到达系统, 任意工作流  $w$  被建模为一个有向无环图  $G_w = (V_w, E_w)$ , 其中节点代表计算任务, 边代表任务间的偏序依赖关系。每个任务  $V_i^w$  (其中  $i$  为工作流  $w$  中第  $i$  个任务) 具有特定的计算负载  $W_i^w$ , 表示要执行的计算指令数量 (单位为百万指令 MI)。任意相连的任务  $V_i^w$  与  $V_j^w$  间 ( $j$  为工作流  $w$  中第  $j$  个任务) 的依赖边  $(V_j^w, V_i^w)$  关联了需要传输的数据量  $F_{w,j,i}$ 。

### 2.2.1 工作流时间模型

本节分别对工作流中各任务的开始时间、完成时间、执行时间和任务间的通信时间进行建模, 从而构建一个完整的工作流时间模型。

本文考虑的批次式多工作流调度场景中, 在每个调度周期开始时, 待调度的多个工作流作为同一批次同时到达, 统一到达时刻记为  $t_0$ 。记任务  $V_i^w$  的前驱任务集合为  $\text{Pred}(V_i^w)$ 。则任务  $V_i^w$  的最早开始时间为:

$$T_{w,i}^{\text{start}} = \max \left\{ t_0, A(S_l^k, V_i^w), \max_{V_j^w \in \text{Pred}(V_i^w)} (T_{w,j}^{\text{finish}} + T_{\text{comm}}(V_j^w, V_i^w)) \right\} \quad (1)$$

其中,  $A(S_l^k, V_i^w)$  表示服务器  $S_l^k$  能够接纳该任务的最早可用时刻,  $T_{w,j}^{\text{finish}}$  表示前驱任务  $V_j^w$  的完成时刻,  $T_{\text{comm}}(V_j^w, V_i^w)$  表示任务  $V_j^w$  与任务  $V_i^w$  之间的数据传输时间。对于不存在前驱任务的工作流入口任务, 其开始时间为:

$$T_{w,i}^{\text{start}} = \max \{ t_0, A(S_l^k, V_i^w) \} \quad (2)$$

任务  $V_i^w$  的最终完成时间可表示为:

$$T_{w,i}^{\text{finish}} = T_{w,i}^{\text{start}} + T_{\text{exec}}(V_i^w) \quad (3)$$

其中,  $T_{\text{exec}}(V_i^w)$  为  $V_i^w$  的执行时间。

任务  $V_i^w$  的执行时间  $T_{\text{exec}}(V_i^w)$  取决于其总计算负载与被分配服务器的计算能力, 由该任务可以被

调度至地理分布式数据中心集群中的任意服务器  $S_l^k$ , 可以使用一个二元决策变量  $x_{w,i,k,l}$  表示任意任务  $V_i^w$  是否被调度到服务器  $S_l^k$  中执行计算。通过遍历  $N$  个数据中心集群中所有服务器, 得到最终执行时间表达式为:

$$T_{\text{exec}}(V_i^w) = \sum_{k=1}^N \sum_{l=1}^{\omega_k} x_{w,i,k,l} \frac{W_i^w}{\zeta_{k,l}} \quad (4)$$

式中:  $\zeta_{k,l}$  为该服务器  $S_l^k$  的最大的固定计算频率, 单位为每秒百万指令 (MIPS);  $W_i^w$  为任务  $V_i^w$  的计算负载, 单位为百万指令 (MI)。

当存在依赖关系的两个任务  $V_j^w$  和  $V_i^w$  被分配到不同数据中心的物理服务器时, 会产生通信开销  $T_{\text{comm}}(V_j^w, V_i^w)$ 。本文假设数据中心内部和数据中心之间的传输路径在单次调度周期内保持稳定, 链路容量已知, 路由、排队等平均开销被等效计入有效带宽参数。在此基础上, 本文分别设置数据中心内部带宽和数据中心间瓶颈带宽, 以重点区分体现域内传输与跨域传输在通信时延方面的差异, 其表达式为:

$$T_{\text{comm}}(V_j^w, V_i^w) = \frac{F_{w,j,i}}{(1 - e_{j,i}) \cdot B_{\text{server}} + e_{j,i} \cdot B_{\text{dc}}} \quad (5)$$

$$e_{j,i} = \begin{cases} 0, & \text{如果 } (V_j^w, V_i^w) \text{ 在同一数据中心中;} \\ 1, & \text{如果 } (V_j^w, V_i^w) \text{ 在两个不同数据中心中。} \end{cases}$$

其中,  $B_{\text{server}}$  表示数据中心内网络的瓶颈带宽;  $B_{\text{dc}}$  表示数据中心间的瓶颈带宽。

### 2.2.2 计算任务能耗模型

在电算协同调度场景中, 服务器执行计算任务是主要的能耗来源<sup>[44]</sup>。且由于本文主要关注任务调度导致的能耗差异, 因此只采用服务器空闲功耗与峰值功耗对利用率区间进行简单线性插值, 仿真模拟以 CPU 计算为主的计算任务在服务器上运行时, 服务器功耗随 CPU 利用率增加而上升的基本特征。通过决策变量  $x_{w,i,k,l}$  来选择任务所在的服务器, 可以定义任务  $V_i^w$  在  $t$  时刻的功耗为:

$$P_{S_l^k}^k(t) = \sum_{k=1}^N \sum_{l=1}^{\omega_k} x_{w,i,k,l} \cdot \left( P_{S_l^k}^{\text{static}} + \left( P_{S_l^k}^{\text{max}} - P_{S_l^k}^{\text{static}} \right) \cdot U_{S_l^k}^k(t) \right) \quad (6)$$

其中,  $P_{S_l^k}^{\text{static}}$  为服务器  $S_l^k$  的静态功率, 此时该服务器 CPU 利用率为 0%;  $P_{S_l^k}^{\text{max}}$  为服务器  $S_l^k$  最大功率,

此时该服务器 CPU 利用率为 100%， $U_{S_l^k}(t)$  为服务器  $S_l^k$  在  $t$  时刻的 CPU 利用率。

因此，任务的能耗  $E(V_i^w, S_l^k)$  为任务  $V_i^w$  在服务器  $S_l^k$  中运行时所产生电力能耗的总和。对于工作流图中任意一个任务  $V_i^w \in V_w$ ，其能耗成本  $EV_i^w, S_l^k$  可以建模为任务执行期间，所在处理器功耗对时间的积分：

$$E(V_i^w, S_l^k) = \int_{T_{w,i}^{\text{start}}}^{T_{w,i}^{\text{finish}}} (P_{S_l^k}(t)) dt \quad (7)$$

### 2.3 碳排放模型

在数据中心并网运行模式下，受限于电能的同质混合传输特性，用户侧无法从物理层面直接区分电力的具体来源<sup>[45]</sup>。因此，本文采用区域电网实时平均碳强度（carbon intensity, CI）作为描述电力侧平均碳排放属性。CI 值较低表示该区域单位电能的平均碳排放较低。具体而言，本模型采用的电网碳强度模型  $CI_k(t)$  定义为在特定地理区域  $k$  的电网中， $t$  时刻每消耗单位电能所产生的碳排放量，它是一个动态变化的量，其数值主要取决于该时刻电网中包括煤电、天然气、水电、风能和太阳能等各类发电来源的实时组合<sup>[46]</sup>。可通过各类电源的发电量与其各自的排放因子进行加权平均计算得出：

$$CI_k(t) = \frac{\sum_{c \in C_k} P_c(t) \times EF_c}{\sum_{c \in C_k} P_c(t)} \quad (8)$$

其中， $C_k$  代表区域电网中的所有发电来源集合， $P_c(t)$  为电源  $c$  在时刻的发电功率， $EF_c$  为电源的碳排放因子。

基于上述碳强度模型，可以精确计算任务  $V_i^w$  执行所产生的碳排放：

$$\begin{aligned} C(V_i^w, S_l^k) &= \int_{T_{w,i}^{\text{start}}}^{T_{w,i}^{\text{finish}}} (P_{S_l^k}(t) \cdot CI_k(t)) dt \\ &\approx E(V_i^w, S_l^k) \cdot \overline{CI}_k \end{aligned} \quad (9)$$

其中， $\overline{CI}_k$  为任务  $V_i^w$  执行时间区间中数据中心  $D_k$  的平均碳强度。

### 2.4 算力碳效模型

由于电算协同调度场景下地理分布式数据中心所处区域电网碳强度具有显著时变特性，且不同算力资源存在异构性。为此，本文建立了用于关联计算任务与电力供应的算力碳效模型，刻画算力资源

设施在当前电网碳强度下提供单位算力服务的低碳能力。与仅考虑服务器计算速度或能耗不同，算力碳效同时反映了算力资源自身属性，算力资源处理计算任务的能力以及与算力资源匹配的区域电力供电情况，为后续调度算法提供资源低碳性表征，使电算调度智能体能够在任务-资源匹配过程中感知算力迁移对碳排放的影响。

本文定义服务器  $S_l^k$  在时刻  $t$  的单位算力碳效分别为：

$$\chi_{k,l}(t) = \frac{\zeta_{k,l}}{P_{S_l^k}(t) CI_k(t) + \epsilon} \quad (10)$$

其中， $\chi_{k,l}(t)$  为服务器算力碳效，其值越大表示单位算力对应的碳排放越低； $\epsilon$  为避免分母为零的极小常数。

### 2.5 优化目标

本文的优化目标是在满足工作流任务偏序依赖、服务器资源容量等约束的前提下，保障多工作流作业批次在截止时间内完成，并最小化系统总碳排放量。具体而言，调度策略需要决定每个任务  $V_i^w$  被分配到哪个数据中心  $D_k$  中的服务器  $S_l^k$  上执行，使任务尽可能迁移至低碳强度供电区域，同时避免因跨域传输和资源竞争导致作业批次完工时间超过截止时间。因此，电算协同调度优化问题可描述为：

$$\min \{C_{\text{total}}\} \quad \text{s.t. } T_{\text{makespan}} \leq MD \quad (11)$$

其中，系统总碳排放量  $C_{\text{total}}$  表示所有工作流任务执行过程中产生的碳排放总和，系统完工时间  $T_{\text{makespan}}$  表示所有工作流中最后一个任务完成的时刻，MD 为本批次多工作流作业截止时间。

$$\begin{aligned} C_{\text{total}} &= \sum_{w \in W} \sum_{V_i^w \in V_w} \sum_{k=1}^N \sum_{l=1}^{\omega_k} x_{w,i;k,l} E_i^w(S_l^k) \overline{CI}_k(T_{w,i}^{\text{start}}, T_{w,i}^{\text{finish}}) \end{aligned} \quad (12)$$

$$T_{\text{makespan}} = \max_{w \in W} \max_{V_i^w \in G_w} T_{w,i}^{\text{finish}} \quad (13)$$

约束条件如下：

$$C1: \sum_{k=1}^N \sum_{l=1}^{\omega_k} x_{w,i;k,l} = 1, \forall w \in W, V_i^w \in G_w \quad (14)$$

$$C2: T_{w,i}^{\text{finish}} = T_{w,i}^{\text{start}} + \sum_{k=1}^N \sum_{l=1}^{\omega_k} x_{w,i;k,l} T_{\text{exec}}(V_i^w, S_l^k), \quad (15)$$

$$\forall V_i^w \in G_w$$

$$C3: T_{w,i}^{\text{start}} \geq T_{w,i}^{\text{finish}} + T_{\text{comm}}(V_j^w, V_i^w), V_j^w \in \text{Pred}(V_i^w) \quad (16)$$

$$C4: x_{w,i;k,l} m_i^w \leq M_{k,l}^{\text{mem}}, \forall V_i^w \in G_w \quad (17)$$

$$C5: T_{w,i}^{\text{start}} \geq t_0, \forall w \in W, V_i^w \in G_w \quad (18)$$

其中,  $E_i^w(S_i^k)$  为任务  $V_i^w$  在服务器  $S_i^k$  上执行所消耗的电能;  $\overline{CI}_k(T_{w,i}^{\text{start}}, T_{w,i}^{\text{finish}})$  为任务执行时间区间  $[T_{w,i}^{\text{start}}, T_{w,i}^{\text{finish}}]$  内数据中心  $D_k$  所在区域电网的平均碳强度;  $m_i^w$  为任务  $V_i^w$  的内存需求;  $M_{k,l}^{\text{mem}}$  为服务器  $S_i^k$  的内存容量。

### 3 GINEConv-PPO电算协同调度机制

针对公式(11)所示的NP难问题, 本文设计了如图2所示的GINEConv-PPO电算协同调度框架。首先, 利用先验时间规划算法, 根据任务在工作流中的紧急程度为所有任务计算出全局优先级。随后, 使用考虑边特征的图同构网络对近端策略优化算法进行优化, 完成以批次截止时间约束下的碳排放最小化为目标的最优任务调度。

#### 3.1 先验时间规划算法

在多工作流电算协同调度场景中, 不同工作流任务之间存在复杂的偏序依赖关系, 且多个工作流会同时竞争分布式数据中心中的异构服务器资源。若仅依据任务就绪状态进行空间分配, 调度智能体容易忽略位于长关键链上的任务, 进而导致工作流

整体完工时间延长。为此, 本文设计一种先验时间规划算法, 在强化学习调度前对任务在关键链中的位置和潜在资源竞争风险进行预估, 并将其作为引导信息辅助调度模型。

首先, 本算法的计算依赖于对系统平均性能的宏观估计, 包括任务的估算执行时间  $\hat{T}_{\text{exec}}(V_i^w)$  和估算通信时间  $\hat{T}_{\text{comm}}(V_i^w, V_z^w)$ :

$$\hat{T}_{\text{exec}}(V_i^w) = \frac{W_i^w \cdot \sum_{k=1}^N \omega_k}{\sum_{k=1}^N \sum_{l=1}^{\omega_k} \zeta_{k,l}} \quad (19)$$

$$\hat{T}_{\text{comm}}(V_i^w, V_z^w) = \frac{F_{w,i,z} \cdot \left( \frac{1}{B_{\text{dc}}} + \frac{1}{B_{\text{server}}} \right)}{2} \quad (20)$$

随后, 在每个工作流内部按照逆拓扑顺序计算任务的剩余关键链长度<sup>[27]</sup>。对于无后继任务, 其剩余关键链长度等于自身平均执行时间; 对于存在后继任务的节点, 其剩余关键链长度由自身平均执行时间和后继任务中最长剩余关键链共同决定, 为了进一步反映宽层任务带来的资源竞争, 本文引入瓶颈层修正项。设任务  $V_i^w$  所在层及其相邻层的最大宽度为  $b_i^w$ , 全部工作流中的最大层宽为  $b_{\text{max}}$ , 则  $V_i^w$  的剩余关键链长度为:

$$Y_{V_i^w} = \hat{T}_{\text{exec}}(V_i^w) + \max_{V_z^w \in \text{AR}_i^w} \left( \hat{T}_{\text{comm}}(V_i^w, V_z^w) + Y_{V_z^w} \right) + \beta \hat{T}_{\text{exec}}(V_i^w) \frac{b_i^w}{b_{\text{max}}} \quad (21)$$




图2 GINEConv-PPO电算协同调度架构图

其中,  $AR_i^w$  是任务  $V_i^w$  的后继任务集合,  $V_z^w$  为任务  $V_i^w$  的后继任务,  $\beta$  为瓶颈层调节系数, 用于控制层宽因素对任务时间优先级的影响强度, 默认设置为 0.5。

在得到所有工作流中任务的关键链长度后, 在当前多工作流实例的全部真实任务上执行全局归一化:

$$p_i^w = \frac{Y_{V_i^w}}{\max_{u \in \bigcup_{w \in W} V_w} Y_u} \quad (22)$$

其中,  $p_i^w \in [0,1]$  表示任务  $V_i^w$  的先验时间优先级;  $W$  为当前调度周期内的工作流集合。数值越大, 说明该任务位于更长的剩余关键链上, 或处于更容易产生资源竞争的并发层附近, 其延迟更可能扩大整体完工时间。

### 3.2 马尔可夫决策过程建模

在完成全局任务的优先级计算后, 本文聚焦于将每一个待执行的任务精准地匹配到地理分布式数据中心内的最优物理服务器上。考虑到该决策过程具有高度的动态性、复杂的约束条件以及对实时环境的感知需求, 引入深度强化学习作为核心求解方法, 寻找能够兼顾最小化碳排放与满足服务质量双重目标的动态调度策略。本节将首先对该问题马尔可夫决策过程中的状态, 动作以及奖励进行形式化建模。

#### 3.2.1 状态空间

为实现对高度动态调度环境的精确感知, 需要在每个决策时刻获取一个能够全面反映系统状态的综合性输入。因此, 首先构建一个可以表征任务在服务器节点间调度的异构图  $G_{sch} = (V_{sch}, E_{sch})$ 。在该图中, 节点集  $V_{sch}$  包含任务节点与服务器节点两类实体, 边集  $E_{sch}$  定义了节点间的相互关系, 由任务偏序依赖关系  $CP(V_i^w, V_z^w)$  与任务-服务器匹配关系  $TD(V_i^w, S_l^k)$  构成。

$$\mathbf{F}_{V_i^w} = [\mathbf{F}_{V_i^w}^{ready}, \mathbf{F}_{V_i^w}^{assigned}, \mathbf{F}_{V_i^w}^{workload}, \mathbf{F}_{V_i^w}^{priority}] \quad (23)$$

$$\mathbf{F}_{S_l^k} = [\mathbf{F}_{S_l^k}^{speed}, \mathbf{F}_{S_l^k}^{avail}, \mathbf{F}_{S_l^k}^{CI}] \quad (24)$$

$$\mathbf{F}_{CP(V_i^w, V_z^w)} = [\mathbf{F}_{CP}^{dep}], \quad \mathbf{F}_{CP}^{dep} = 1 \quad (25)$$

$$\mathbf{F}_{TD(V_i^w, S_l^k)} = [\mathbf{F}_{TD}^{duration}, \mathbf{F}_{TD}^{carbon}] \quad (26)$$

其中,  $\mathbf{F}_{V_i^w}^{ready} \in \{0,1\}$  表示任务  $V_i^w$  当前是否满足前驱

约束并可被调度;  $\mathbf{F}_{V_i^w}^{assigned} \in \{0,1\}$  表示该任务是否已经完成分配;  $\mathbf{F}_{V_i^w}^{workload}$  表示任务计算负载, 并由任务长度按当前任务集合中的最大长度归一化得到;  $\mathbf{F}_{V_i^w}^{priority} \in [0,1]$  表示由先验时间规划算法生成的任务优先级, 用于反映任务在工作流关键链中的位置及其潜在资源竞争风险。对于服务器节点,  $\mathbf{F}_{S_l^k}^{speed}$  表示节点计算能力, 由 CPU 计算速度归一化得到;  $\mathbf{F}_{S_l^k}^{avail}$  表示该节点的预计可用时间, 即当前已分配任务完成后该服务器的最早空闲时刻;  $\mathbf{F}_{S_l^k}^{CI}$

表示该节点在当前可用时刻的算力碳效, 按式 (10) 计算并归一化得到, 综合表征服务器计算能力、功耗与区域电网碳强度。对于边特征, 任务依赖边  $CP(V_i^w, V_z^w)$  用常量特征  $\mathbf{F}_{CP}^{dep} = 1$  表示有向前驱约束; 任务-服务器匹配边  $TD(V_i^w, S_l^k)$  则显式编码候选动作的执行后果,  $\mathbf{F}_{TD}^{duration}$  表示任务  $V_i^w$  在服务器  $S_l^k$  上的预计执行时间, 并按全局时间尺度归一化;  $\mathbf{F}_{TD}^{carbon}$  表示该候选调度动作产生的预计碳成本, 由任务能耗与其预计执行时间区间内的平均碳强度计算得到, 并按当前候选动作中的最大碳成本归一化。

在图嵌入阶段, 本文采用文献[47]提出的 GINEConv 网络对上述异构图状态进行特征提取。与传统图同构网络仅聚合邻居节点特征不同, GINEConv 在消息传递过程中显式引入边特征, 因而能够同时感知任务依赖关系以及候选任务-服务器匹配动作所对应的执行时间和碳排放代价。对于当前调度时刻构建的异构图, 首先对特征进行编码, 将不同类型的原始特征统一投影至 16 维表示空间:

$$\mathbf{h}_{w,i}^{T,(0)} = \text{MLP}_T(\mathbf{F}_{V_i^w}), \mathbf{h}_{k,l}^{S,(0)} = \text{MLP}_S(\mathbf{F}_{S_l^k}) \quad (27)$$

$$\begin{aligned} \mathbf{e}_{V_i^w, V_z^w}^{dep} &= \text{MLP}_{dep}(\mathbf{F}_{CP(V_i^w, V_z^w)}), \\ \mathbf{e}_{V_i^w, S_l^k}^{mat} &= \text{MLP}_{mat}(\mathbf{F}_{TD(V_i^w, S_l^k)}) \end{aligned} \quad (28)$$

其中,  $\mathbf{h}_{w,i}^{T,(0)}, \mathbf{h}_{k,l}^{S,(0)}, \mathbf{e}_{V_i^w, V_z^w}^{dep}, \mathbf{e}_{V_i^w, S_l^k}^{mat}$  表示经过编码器处理后的嵌入向量。随后, 将编码后的节点特征与边特征输入 GINEConv 网络进行多轮消息聚合。第  $q$  层 GINEConv 的更新过程可表示为:

$$\mathbf{h}_v^{(q+1)} = \text{MLP}^{(q)} \left( \left( 1 + \epsilon^{(q)} \right) \mathbf{h}_v^{(q)} + \sum_{u \in \mathcal{N}(v)} \sigma(\mathbf{h}_u^{(q)} + \mathbf{e}_{u,v}) \right) \quad (29)$$

其中,  $\mathbf{h}_v^{(q)}$  表示节点  $v$  在第  $q$  层的嵌入向量;  $\mathcal{N}(v)$  表示节点  $v$  的邻居节点集合;  $\mathbf{e}_{u,v}$  表示边  $(u,v)$  的嵌入向量;  $\epsilon^{(q)}$  为可学习或固定的中心节点权重系数;  $\sigma(\cdot)$  为非线性 ReLU 激活函数;  $\text{MLP}^{(q)}$  为第  $q$  层的特征变换网络。经过  $Q$  层 GINEConv 聚合更新后可得:

$$\mathbf{z}_{w,i}^T = \mathbf{h}_{w,i}^{T,(Q)}, \mathbf{z}_{k,l}^S = \mathbf{h}_{k,l}^{S,(Q)} \quad (30)$$

其中,  $\mathbf{z}_{w,i}^T$  为任务节点嵌入向量,  $\mathbf{z}_{k,l}^S$  为服务器节点嵌入向量。

此时, 可得当前状态空间  $s_t$ , 即全局嵌入向量  $\mathbf{z}_G$ :

$$s_t = \mathbf{z}_G = \left( \frac{1}{\text{NT}} \sum_{i=1}^{\text{NT}} \mathbf{z}_i^T \right) // \left( \frac{1}{\text{NS}} \sum_{l=1}^{\text{NS}} \mathbf{z}_l^S \right) \quad (31)$$

其中, NT 和 NS 分别表示当前异构图中的任务节点数和服务器节点数。

可设任务与服务器的匹配边嵌入向量为  $\mathbf{z}_{w,i,k,l}^{\text{edge}}$ :

$$\mathbf{z}_{w,i,k,l}^{\text{edge}} = \mathbf{z}_{w,i}^T \| \mathbf{z}_{k,l}^S \| \mathbf{z}_G \quad (32)$$

### 3.2.2 动作空间

对于本文设计的 GINEConv-PPO 智能体, 其在  $t$  时刻的动作空间为  $A_t$ , 此时该智能体选择的任意动作  $a_t \in A_t$  定义为一个二元组  $(V_i^w, S_l^k)$ , 表示将当前待调度任务  $V_i^w$  分配至物理服务器  $S_l^k$  中执行。根据实际调度情况, 其有限动作空间受到式 (14) - 式 (18) 的约束, 不满足此约束的非法候选动作本文通过动作掩码机制将其排除。

### 3.2.3 奖励函数

本文强化学习调度智能体的目标是在保障 workflow 服务质量的前提下最小化系统碳排放。为此, 本文采用时间约束下的碳优化复合奖励函数, 将时间调度质量作为碳优化的安全边界, 在不显著恶化完工时间的同时进一步引导智能体选择低碳调度方案。当智能体在状态  $S_t$  下选择动作  $a_t = (V_i^w, S_l^k)$  后, 其即时奖励定义为:

$$R_t = -(r_t^C + r_t^T + r_t^F) \quad (33)$$

$$\begin{cases} r_t^C = g_t^T \left( \frac{C(V_i^w, S_l^k) - C_{\text{best}}(V_i^w)}{C(V_i^w, S_l^k)} + \Delta\Phi_C \right) \\ r_t^T = \frac{T_{w,i}^{\text{finish}} - \text{EFT}_{w,i}^{\min}}{T_{w,i}^{\text{finish}}} - p_i^w + \Delta\Phi_T \\ r_t^F = \mathbb{I}_{\text{end}} \left( g_t^{\text{TEND}} \left( \frac{C_{\text{total}} - C_{lb}}{C_{lb}} \right) + \mu \frac{\max(0, M - \text{MD})}{\text{MD}} \right) \end{cases} \quad (34)$$

其中,  $r_t^C$  为碳排放惩罚项, 表征了当前动作碳成本相对于当前可行动作集中最优碳成本的偏离程度以及该动作对全局预估碳排放值的影响;  $r_t^T$  为时间惩罚项, 表征了当前动作导致任务完工时间相对于当前可行动作集中最优完工时间的偏离程度以及该动作对全局预估完工时间的影响;  $r_t^F$  为终局惩罚项, 表征了全局视角下批次截止时间满足情况和碳排放的优化程度;  $\text{EFT}_{w,i}^{\min}$  表示任务  $V_i^w$  在当前状态下的最早完成时间估计值;  $C_{\text{best}}(V_i^w)$  表示任务  $V_i^w$  在当前可行服务器集合上的最小预测碳排放;  $\Delta\Phi_T$  和  $\Delta\Phi_C$  分别为时间势函数和碳排势函数变化量, 刻画了动作执行后系统未来调度空间的变化;  $\mathbb{I}_{\text{end}}$  表示当前是否为终止状态;  $C_{\text{total}}$  为所有任务执行完成后的系统总碳排放量;  $C_{lb}$  为当前任务集合在理想低碳调度下的碳排放下界;  $M$  为最终 workflow 完工时间; MD 为服务质量约束对应的截止时间;  $g_t^T$  为时间安全门控函数, 用于控制当前动作是否参与碳排放奖励评价, 当前动作预估时间超出时间预算时该值为 0, 反之为 1;  $g_t^{\text{TEND}}$  为终局时间安全门控函数, 当最终完工时间违反截止时间约束时为 0, 反之为 1。

$$\begin{cases} \Phi_T(s_t) = \max \left\{ \max_{S_l^k \in \mathcal{S}} T_{k,l}^{\text{ava}}(s_t), \max_{V_i^w \in \mathcal{V}^{\text{uns}}(s_t)} \text{EFT}_{w,i}^{\min} \right\} \\ \Phi_C(s_t) = C^{\text{done}}(s_t) + \sum_{V_i^w \in \mathcal{V}^{\text{uns}}(s_t)} C_{\text{best}}(V_i^w) \end{cases} \quad (35)$$

其中,  $\Phi_T(s_t)$  为时间势函数;  $\Phi_C(s_t)$  为碳排放势函数;  $T_{k,l}^{\text{ava}}(s_t)$  表示服务器  $S_l^k$  的最早可用时间;  $C^{\text{done}}(s_t)$  表示已分配任务产生的累计实际碳排放。

### 3.3 GINEConv-PPO 电算协同调度策略训练方法

前文通过先验时间规划算法为每个任务构建了反映关键任务链位置与资源竞争程度的优先级特征, 并在状态空间建模中利用图嵌入方法获得了候选任务-服务器匹配动作的向量表示。在此基础上, 本文采用近端策略优化算法训练调度智能体, 使其

能够在动态调度过程中综合感知任务时间紧迫性、服务器资源状态、候选动作执行时间以及碳排放代价，从而学习兼顾完工时间与碳排放量的调度策略。

PPO 通过其独特的裁剪替代目标函数，在保证采样效率的同时显著提升了训练过程的稳定性，使其在处理高维、连续状态与离散动作空间的复杂问题时表现尤为出色<sup>[48]</sup>。本文研究的 GINEConv-PPO 智能体以 GINEConv 图嵌入网络作为共享的特征提取器，其输出的节点嵌入和全局图嵌入被同时提供给策略和价值网络。

在每个决策时刻  $t$ ，策略网络以候选任务-服务器匹配边向量  $\mathbf{z}_{i,l}^{\text{edge}}$  为输入，对可行动作集合  $\mathcal{A}_t$  中的每个候选动作进行评分，并通过 Softmax 得到动作选择概率：

$$\pi_{\theta}(a_t | s_t) = \text{Softmax}\left(\text{MLP}_{\pi}\left(\mathbf{z}_{i,l}^{\text{edge}}\right)\right), a_t = (V_i^w, S_l^k) \in \mathcal{A}_t \quad (36)$$

其中， $\pi_{\theta}$  为参数为  $\theta$  的策略网络； $s_t$  表示时刻  $t$  的调度状态。

价值网络以全局图嵌入向量  $\mathbf{z}_G$  为输入，对当前调度状态的长期收益进行估计：

$$V_{\psi}(s_t) = \text{MLP}_V(\mathbf{z}_G) \quad (37)$$

其中， $V_{\psi}$  为参数为  $\psi$  的价值网络。价值网络用于提供状态价值基线，辅助衡量当前动作相对于平均调度收益的优劣。

智能体按照当前策略与调度环境交互，获得由  $(s_t, a_t, R_t, s_{t+1})$  构成的轨迹样本。为评估动作优势，首先计算时序差分误差：

$$\delta_t = R_t + \gamma V_{\psi}(s_{t+1}) - V_{\psi}(s_t) \quad (38)$$

其中， $R_t$  为执行动作  $a_t$  后获得的即时奖励， $\gamma$  为折扣因子。进一步采用广义优势估计得到优势函数：

$$\hat{A}_t = \sum_{k=0}^{\infty} (\gamma \lambda)^k \delta_{t+k} \quad (39)$$

其中， $\lambda$  为优势估计平滑系数，用于平衡估计偏差与方差。PPO 通过裁剪新旧策略概率比限制策略更新幅度，其目标函数为：

$$L^{\text{CLIP}}(\theta) = \mathbb{E}_t \left[ \min \left( \rho_t(\theta) \hat{A}_t, \text{clip}(\rho_t(\theta), 1 - \epsilon, 1 + \epsilon) \hat{A}_t \right) \right] \quad (40)$$

$$\rho_t(\theta) = \frac{\pi_{\theta}(a_t | s_t)}{\pi_{\theta_{\text{old}}}(a_t | s_t)} \quad (41)$$

其中， $\rho_t(\theta)$  表示新旧策略下选择同一动作的概率比； $\theta_{\text{old}}$  为下采样轨迹时的旧策略参数； $\epsilon$  为裁剪系数。该机制能够避免策略参数单次更新过大，提高训练稳定性。

## 4 仿真及结果分析

### 4.1 实验环境设置

本研究采用 PyTorch 框架构建了 GINEConv-PPO 智能体进行了深度强化训练，具体训练参数如表 1 所示。所有实验均在配备了 AMD EPYC 7763 64-Core Processor 512G RAM 及 NVIDIA GeForce RTX 4090 GPU\*4 的服务器上进行。训练奖励曲线如图 3 所示。




图3 GINEConv-PPO 智能体训练奖励曲线

表1 GINEConv-PPO 训练参数

| 参数              | 数值                 | 参数          | 数值   |
|-----------------|--------------------|-------------|------|
| 学习率             | $1 \times 10^{-4}$ | PPO 更新训练轮数  | 4    |
| 批次大小            | 8192               | 熵系数         | 0.01 |
| 折扣因子            | 0.995              | 目标 KL 散度    | 0.02 |
| GAE $\lambda$ 值 | 0.95               | 编码器隐藏层维度    | 64   |
| 裁剪系数            | 0.15               | GINEConv 层数 | 3    |

智能体完成训练后，利用云环境模拟工具 CloudSim 搭建跨域调度仿真系统<sup>[49]</sup>，仿真系统中共设置了四个分别由加利福尼亚州独立系统运营商，美国太平洋电力公司东部电网，美国西南电网以及内华达电力公司进行区域供电的数据中心 D1，D2，D3 和 D4，每个数据中心内部署了异构的服务

器集群,为模拟现实世界中的资源异构性,本文从SPECpower公开测试结果中选取三类真实CPU服务器配置,其计算能力、空闲功耗和满载功耗参数如表2所示<sup>[50]</sup>。三类服务器具有不同的空闲能耗水平和动态功耗区间,能够充分体现异构服务器在计算性能和能耗特性方面的差异。

表2 服务器参数

| 名称   | 核心数 | CPU速度/<br>GIPS | RAM<br>/GB | 空闲功<br>耗/W | 峰值功<br>耗/W |
|------|-----|----------------|------------|------------|------------|
| 服务器A | 56  | 604.8          | 64         | 50         | 432        |
| 服务器B | 48  | 587.52         | 64         | 227        | 895        |
| 服务器C | 32  | 332.8          | 64         | 110        | 446        |

服务器间的网络带宽根据其拓扑位置进行分层设置。跨域调度仿真系统的碳强度数据来源于公开数据集Electricity Maps<sup>[51]</sup>。本研究为上述四个模拟数据中心所在区域引入了其真实历史碳强度的小时级时间序列数据,以确保仿真环境能精确反映电网的时空动态性。为获取典型日特征,采用均值法处理了2024年的数据,得到了四个数据中心配电网的典型日碳强度特征,由图4可见,四个数据中心所在区域的典型日碳强度在水平和变化趋势上均存在明显差异。数据中心D1的碳强度全天处于相对较高水平,日内波动较小;D2在夜间及早晚时段保持较高碳强度,而在中午前后快速下降并形成持续低碳窗口;D3的变化相对平缓,其碳强度由早间逐步降低,在中午附近达到低谷后回升;D4的日内波动最为显著,在凌晨和中午附近出现低值,而在上午及傍晚附近出现高值。各区域低碳时段并不同步,说明地理分布式数据中心之间具有可利用的碳强度时空互补性,为在截止时间约束下迁移计算任务提供了调度空间。

除此之外,为测试算法的拓扑泛化性和可扩展性,本研究根据实验目的构造了两类科学工作流数据。对于拓扑泛化性实验,采用多个实际的科学应用工作流结构模板进行仿真验证<sup>[52-53]</sup>。对于扩展性实验,采用随机图构造模型作为模板,随机生成不同任务结构、任务数量和计算负载的有向无环图工作流,对本研究所提算法进行扩展性测试<sup>[54]</sup>。

#### 4.2 对比算法与评估指标

为验证本文所提出的基于深度强化学习的数据中心电算协同调度方法(GINEConv-PPO)的性




图4 四个数据中心的碳强度特征

能,本研究选取了HEFT<sup>[27]</sup>、C-GBO<sup>[32]</sup>、Max-Min<sup>[55]</sup>、RR<sup>[55]</sup>、DM-SO<sup>[56]</sup>、WDDQN-RL<sup>[36]</sup>和随机调度(Random)作为基准算法,其中:HEFT是一种经典的启发式列表调度算法,利用工作流DAG的向上排序值和异构处理器最早完成时间进行列表调度,是工作流调度中常用的拓扑感知基准;Max-Min在每个决策点优先处理预计执行时间较长的就绪任务,是一种贪心调度算法的典型代表;RR按固定顺序轮询可用服务器,代表强调资源分配公平的规则方法;C-GBO通过任务—虚拟机映射与任务优先级联合编码,并结合聚类引导和精英扰动增强搜索能力;DM-SO将蛇优化器离散化用于多工作流调度,并通过双变异机制缓解过快收敛;WDDQN-RL通过WDDQN与两级任务—资源决策机制,实现多科学工作流的时间—成本双目标调度;Random则在兼容服务器中随机选择执行位置,作为无信息参照。为保证比较公平,所有基准算法均在本文统一的调度环境中运行,并采用统一的任务批次、资源配置和区域电网碳强度输入等参数。

本文研究对象为一个调度周期内到达的多工作流作业批次。对于该类批处理型计算负载,平台通常要求批次内所有工作流在给定服务窗口内完成。因此,本文采用批次级截止时间约束描述服务质量要求,即 $MD = \max_{w \in W} \max_{V_i^w \in G_w} EFT_{w,i}^{\min} (1 + \rho)$ 。其中 $\rho$ 为批次截止时间容忍因子,用于控制服务质量约束的松紧程度,默认值为0.2。

为从多维度综合评价算法的性能,本文采用完工时间截止占比率(completion-to-dadline ratio,

CDR) 和碳排放量相对偏差 (carbon-emission relative percentage deviation, CRPD) 两个核心指标进行算法比较。如式(42)所示, CDR 用于评估在多次随机实验中多工作流作业批次完工时间是否满足截止时间要求。如式(43)所示, CRPD 用于量化算法在碳减排方面的优化程度, 在每一个场景中计算当前场景下的碳排放量最优值, 再对比所有算法的碳排放量, 衡量其与最优值之间的差距。

$$CDR = \max_{1 \leq r \leq R} \frac{M^{(r)}}{MD^{(r)}} \times 100\% \quad (42)$$

$$CRPD = \frac{C_{alg} - C_{min}}{C_{min}} \times 100\% \quad (43)$$

其中,  $r$  为某次随机编号,  $R$  为最大随机次数,  $M^{(r)}$  为某次随机种子下得到的作业批次完工时间,  $MD^{(r)}$  为某次随机种子下作业批次截止时间;  $C_{alg}$  为某算法下的总碳排放量,  $C_{min}$  为本轮测试最优碳排放量。

### 4.3 实验结果与分析

为全面评估 GINEConv-PPO 算法在批次级截止时间约束下的低碳调度性能, 本文从六个方面开展实验分析。首先, 分析不同任务规模下 GINEConv-PPO 对多工作流作业批次截止时间约束的满足情况; 其次, 在不同工作流拓扑结构下验证模型的任务泛化能力; 再次, 改变并发工作流数量和任务数量, 分析算法在不同负载规模下的截止时间约束碳减排优化效果; 然后, 设置不同批次截止时间容忍因子, 分析服务质量约束松紧程度对碳减排优化空间的影响; 除此之外, 进行核心方法的消融实验, 分析各方法模块的贡献; 最后, 统计不同算法的在线决策时间, 验证所提方法的调度效率。为降低随机性对实验结果的影响, 所有实验均采用 10 个不同的随机种子独立重复实验。

#### 4.3.1 截止时间约束满足性实验

在开展碳排放优化效果对比之前, 首先需要验证所提 GINEConv-PPO 方法是否能够满足多工作流作业批次的截止时间约束。为此, 本文固定并发工作流数量为 10, 并分别设置多工作流作业批次中的总任务数量为 200、300、400 和 500。实验采用完工时间截止占比衡量作业批次总完工时间与批次级截止时间之间的相对关系。图 5 中以 100% 作为截止时间阈值, 当 CDR 低于 100% 时, 表示该批次能够在截止时间前完成。




图5 不同任务数量下不同调度算法的完工时间截止占比率

实验结果表明, 除 Random 外, 各算法在所测试的任务规模下可以满足批次级截止时间约束。其中, GINEConv-PPO 的平均 CDR 随任务规模变化较为平稳, 未随任务数量增加而持续上升。Random 的平均 CDR 也低于 100%, 但实验结果波动较大, 部分任务规模下的误差范围超过截止时间阈值, 存在批次超时的可能。后续碳排放比较将 Random 作为随机分配的空白对照, 呈现未经调度优化的碳排放水平, 并考察其余算法在满足批次级截止时间约束时的碳排放表现。

#### 4.3.2 任务拓扑泛化性实验

为验证所提算法对不同工作流拓扑结构的泛化能力, 本文选取训练阶段未使用的 Montage、Inspirational、CyberShake 和 Epigenomics 四类典型科学工作流, 作为独立测试拓扑进行实验评估<sup>[52-53]</sup>。其中, Montage 具有较多层级, 分支、汇聚和链式依赖并存; Inspirational 的分层结构较为明显, 同一层级包含较多可并行执行的任务; CyberShake 呈现典型的宽型 DAG 结构, 包含大规模并行分支及后续结果汇聚过程; Epigenomics 则兼具流水线式依赖和多阶段分支汇聚特征。四类工作流在层级深度、拓扑宽度和并行程度等方面具有不同特征, 可用于检验调度模型对工作流结构变化的适应能力。表 3 给出了四类工作流的主要拓扑参数。

在实验中, 并发工作流数量保持一致, 分别比较 GINEConv-PPO 与各基准算法在不同工作流拓扑下的碳排放量相对偏差。实验结果如图 6 所示。

从图 6 可以看出, 在 Montage、Inspirational、CyberShake 和 Epigenomics 四类不同拓扑结构工作流

表3 测试 workflow 拓扑参数

| 工作流种类       | 任务数量/个 | 任务层数/层 | 任务计算负载/MI      | 并发工作流数量 |
|-------------|--------|--------|----------------|---------|
| Montage     | 39     | 13     | (50000-100000) | 10      |
| Inspirar    | 51     | 3      | (50000-100000) | 10      |
| CyberShake  | 165    | 5      | (50000-100000) | 10      |
| Epigenomics | 24     | 8      | (50000-100000) | 10      |




图6 不同工作流类型下不同调度算法的碳排放量相对偏差

场景下，GINEConv-PPO 的碳排放量相对偏差均保持在0附近，而其他对比方法的碳排放量相对偏差约为8%~35%。尽管不同方法在各类工作流上的相对表现随拓扑结构变化而有所差异，但本文所提 GINEConv-PPO 方法结合先验时间优先级、任务拓扑结构和区域电网碳强度信息进行联合决策，在不同宽度和深度的有向无环图结构中均取得了较低的碳排放量相对偏差。说明本文所提 GINEConv-PPO 方法既能适应依赖关系复杂的混合型工作流，也能有效处理并行度较高的分层工作流，其调度性能不依赖某一特定工作流结构，而是具有较好的拓扑适应性与泛化能力。

#### 4.3.3 工作流数量与任务数量扩展性实验

在验证了 GINEConv-PPO 算法对不同科学应用背景工作流拓扑的适应性后，本文进一步采用基于随机图模型随机生成的 DAG 工作流，构建可扩展性实验，分别从并发工作流数量和批次任务数量两个维度进行实验分析。首先，将每个工作流的任务数量固定为10，并逐渐增加并发工作流数量。该实验用于模拟调度周期内用户提交工作流数量增加

时的系统负载变化。数据为10次独立实验的均值，误差棒表示 $\pm 1$ 个标准差，实验结果如图7所示。




图7 不同工作流数量下不同调度算法的碳排放量相对偏差

由图7可见，随着工作流数量由10增加至25，GINEConv-PPO 的碳排放量相对偏差始终保持在0附近，而其他对比方法的碳排放量相对偏差主要分布在约6%~21%之间，表明所提方法在不同并发负载下均能获得更接近最优值的低碳调度结果，且性能波动较小。随着工作流数量增加，任务依赖和资源竞争关系更加复杂，以RR为代表的简单固定规则策略算法难以适应多工作流并发下的低碳资源匹配需求，HEFT、C-GBO、WDDQN-RL 等算法虽然在部分负载点存在小幅波动，但整体仍明显高于 GINEConv-PPO。表明本文方法能够在多工作流同时竞争资源的场景下，通过图结构感知，在并发工作流数量变化时稳定感知任务依赖、资源竞争和区域电网碳强度差异，具有较好的多工作流负载泛化能力。

接着进行并发任务数量扩展实验，在固定并发工作流数量为20时，逐步增加单个作业批次中的任务数量。该实验用于模拟 DAG 规模扩展时的调度性能变化，数据为10次独立实验的均值，误差棒表示 $\pm 1$ 个标准差。

实验结果如图8所示，当任务数量由200个增加至500个时，各对比方法的碳排放量相对偏差总体呈上升趋势，由约8%~18%扩大至约15%~27%；相比之下，GINEConv-PPO 在不同任务规模下的碳排放量相对偏差始终保持在0附近，表明所提方法能够在任务规模扩大的情况下持续获得较优

的低碳调度结果。随着任务数量增加，DAG 依赖关系、跨任务通信和资源竞争更加复杂，调度决策空间也随之扩大。传统的启发式算法和强化学习方法难以评估每个任务分配决策对后续调度空间的影响。而本文方法通过 GINEConv 聚合任务节点与服务器节点，构成异构图，有效增强了 PPO 对关键任务、资源状态和区域电网碳强度的联合感知能力，能够更好地适应更大规模的多任务调度场景。




图8 不同任务数量下不同调度算法的碳排放量相对偏差

#### 4.3.4 多工作流作业批次截止时间容忍度实验

多工作流作业批次的批次截止时间容忍因子  $\rho$  决定了作业批次的时间弹性。为分析服务质量约束松紧程度对碳排优化效果的影响，本文分别设置  $\rho$  为 0.2, 0.4 和 0.6，并比较不同算法的碳排放量相对偏差，数据为 10 次独立实验的均值，误差棒表示  $\pm 1$  个标准差，实验结果如图 9 所示。

从图 9 中可以看出，当批次截止时间容忍因子由 0.2 增大至 0.6 时，GINEConv-PPO 始终保持最低的碳排放量相对偏差，说明所提方法能够在不同时间约束松紧程度下稳定获得较优低碳调度结果。随着容忍因子增大，作业批次的时间弹性提高，任务




图9 不同批次截止时间容忍因子下不同调度算法的碳排放量相对偏差

迁移至低碳数据中心或低碳时段的可行空间随之扩大，本文方法利用先验时间规划提供关键链位置和资源竞争风险特征，并结合任务拓扑、资源状态与区域电网碳强度进行联合决策，因而能够更充分地利用新增的时间弹性，将任务安排至低碳数据中心或低碳时段。

#### 4.3.5 核心方法消融实验

为分析先验时间规划、GINEConv 图编码和 PPO 策略学习对调度性能的独立贡献，本文在与主实验相同的仿真环境、工作流批次、服务器配置、碳强度数据和截止时间约束下开展消融实验。实验在保持调度约束的情况下，分别去除先验时间规划模块 (w/o Prior)，GINEConv 图编码模块 (w/o GINEConv)，以及将 PPO 策略替换为规则贪心调度的模型 (w/o PPO)。每组实验采用 10 个随机种子重复运行，并统计平均 CDR、最大 CDR、总碳排放量和 CRPD，结果如表 4 所示。

由表 4 可见，虽然在截止时间约束下，各消融模型的最大 CDR 均低于 100%，但完整的 GINEConv-PPO 模型的总碳排放量取得了最优结果。去除先验时间规划后，模型对关键路径风险的感知能

表 4 消融实验结果

| 方法           | 平均 CDR/% (↓) | 最大 CDR/% (↓) | 平均总碳排放量/g (↓) | CRPD /% (↓) |
|--------------|--------------|--------------|---------------|-------------|
| GINEConv-PPO | 89.83        | 98.75        | 579.90        | 0           |
| w/o Prior    | 99.26        | 99.49        | 635.29        | 9.55        |
| w/o GINEConv | 99.00        | 99.88        | 667.98        | 15.19       |
| w/o PPO      | 98.33        | 99.98        | 629.45        | 8.54        |

力减弱,不利于模型利用低碳资源匹配所需的时间裕度;去除 GINEConv 后,模型对任务拓扑、资源异构性及边特征信息的联合表征能力下降,CRPD 增加至 15.19%;将 PPO 替换为规则贪心调度后,模型难以评估当前资源选择对后续调度空间的长期影响。

#### 4.3.6 算法决策时间实验

为评估所提方法的在线部署可行性,本文在相同软硬件环境和实验设置下,统计了 GINEConv-PPO、HEFT、C-GBO、DM-SO 和 WDDQN-RL 在不同任务规模下完成一次多工作流作业批次调度所需的决策时间。其中,C-GBO 和 DM-SO 的决策时间包括生成调度方案所需的迭代搜索时间,WDDQN-RL 和 GINEConv-PPO 的决策时间为模型在线推理时间,HEFT 的决策时间为在线列表调度过程。当任务数量分别设置为 200、300、400 和 500 时,结果如表 5 所示。

由表 5 可见,GINEConv-PPO 的决策时间虽然

表 5 不同调度算法决策时间对比

| 算法种类         | 任务数量/个 | 决策总时间/s |
|--------------|--------|---------|
| GINEConv-PPO | 200    | 4.46    |
| HEFT         | 200    | 0.08    |
| C-GBO        | 200    | 193.76  |
| DM-SO        | 200    | 82.24   |
| WDDQN-RL     | 200    | 2.26    |
| GINEConv-PPO | 300    | 7.64    |
| HEFT         | 300    | 0.12    |
| C-GBO        | 300    | 270.92  |
| DM-SO        | 300    | 106.79  |
| WDDQN-RL     | 300    | 4.52    |
| GINEConv-PPO | 400    | 12.43   |
| HEFT         | 400    | 0.18    |
| C-GBO        | 400    | 381.37  |
| DM-SO        | 400    | 128.98  |
| WDDQN-RL     | 400    | 8.15    |
| GINEConv-PPO | 500    | 18.91   |
| HEFT         | 500    | 0.29    |
| C-GBO        | 500    | 596.231 |
| DM-SO        | 500    | 165.29  |
| WDDQN-RL     | 500    | 13.35   |

高于 HEFT 和 WDDQN-RL,但低于 C-GBO 和 DM-SO。其额外开销主要来自任务-资源异构图构建、GINEConv 图嵌入及策略网络前向推理。尽管如此,在 200~500 个任务的测试规模下,其批次调度的决策时间仍保持在秒级范围内,能够满足批处理型多工作流作业批次的在线调度需求。结合前述碳排优化结果,所提方法在决策开销与低碳调度性能之间取得了较好权衡,具有一定的在线部署可行性。

## 5 结束语

本文围绕数据中心服务质量保障与新能源供电波动之间的矛盾,研究了电力侧碳强度信号引导的地理分布式数据中心任务调度问题。综合考虑工作流依赖、异构算力资源、跨域通信开销与区域电网碳强度变化,提出了电网碳强度感知的地理异构数据中心任务调度模型,将低碳调度目标分解为任务级算力分配,并提出了融合先验时间规划与图强化学习的 GINEConv-PPO 智能调度方法。仿真结果表明,GINEConv-PPO 能够满足作业批次截止时间约束,以同一场景下各算法取得的最低碳排放量为基准,所提方法的碳排放量相对偏差保持在 0% 附近,其余各基准算法的碳排放量相对偏差最低约为 6%,最高为 35%。证明了通过算力负荷的时空迁移匹配低碳电力供给,是降低实际运行碳排放的有效途径。本文虽然为地理分布式数据中心低碳运行提供了一种可行的任务级电算协同调度方法,但面向更高层次的协同需求与更真实的算力网络架构,系统建模仍有深化空间。未来将进一步引入真实网络拓扑和时变链路状态,并结合流级网络仿真或实际传输数据,研究复杂网络条件对跨域电算协同调度性能的影响。同时,考虑数据中心与配电网的互动机制、本地储能、绿电直供和新能源出力预测,构建面向源-网-荷-储协同的电算联合优化模型,以提升在复杂电力与通信环境下的决策鲁棒性和工程适应性。

## 参考文献:

- [1] 中国信息通信研究院产业与规划所,内蒙古和林格尔新区.中国绿色算力发展研究报告(2024年)[R].北京:中国信息通信研究院,2024. CAICT INSTITUTE OF INDUSTRY AND PLANNING, INNER MONGOLIA HELINGER NEW AREA. China green computing power development research report (2024)[R]. Beijing: China Academy of In-

- formation and Communications Technology, 2024.
- [2] 李洁, 王月. 算力基础设施的现状、趋势和对策建议[J]. 信息通信技术与政策, 2022(3): 2-6.
- Li J, Wang Y. The status, trends and suggestions of computing infrastructure[J]. Information and Communications Technology and Policy, 2022(3): 2-6.
- [3] 工业和信息化部. 工业和信息化部关于印发《新型数据中心发展三年行动计划(2021—2023年)》的通知: 工信部通信(2021)76号[EB/OL]. (2021-07-04) [2026-06-30]. [https://www.miit.gov.cn/zwgk/zcwj/wjfb/txy/art/2021/art\\_d6068e784bef47ca9cda927daa42d41e.html](https://www.miit.gov.cn/zwgk/zcwj/wjfb/txy/art/2021/art_d6068e784bef47ca9cda927daa42d41e.html). MINISTRY OF INDUSTRY AND INFORMATION TECHNOLOGY. Notice of the Ministry of Industry and Information Technology on issuing the Three-Year Action Plan for the Development of New Data Centers (2021—2023): MIIT Communications [2021]No. 76[EB/OL]. (2021-07-04) [2026-06-30]. [https://www.miit.gov.cn/zwgk/zcwj/wjfb/txy/art/2021/art\\_d6068e784bef47ca9cda927daa42d41e.html](https://www.miit.gov.cn/zwgk/zcwj/wjfb/txy/art/2021/art_d6068e784bef47ca9cda927daa42d41e.html).
- [4] 国家发展改革委, 国家能源局, 工业和信息化部, 等. 国家发展改革委等部门关于促进可再生能源绿色电力证书市场高质量发展的意见: 发改能源(2025)262号[EB/OL]. (2025-03-06) [2026-06-30]. [https://www.ndrc.gov.cn/xxgk/zcfb/tz/202503/t20250318\\_1396627.html](https://www.ndrc.gov.cn/xxgk/zcfb/tz/202503/t20250318_1396627.html). NATIONAL DEVELOPMENT AND REFORM COMMISSION, NATIONAL ENERGY ADMINISTRATION, MINISTRY OF INDUSTRY AND INFORMATION TECHNOLOGY, et al. Opinions of the National Development and Reform Commission and other departments on promoting the high-quality development of the renewable energy green electricity certificate market: NDRC Energy [2025]No. 262 [EB/OL]. (2025-03-06) [2026-06-30]. [https://www.ndrc.gov.cn/xxgk/zcfb/tz/202503/t20250318\\_1396627.html](https://www.ndrc.gov.cn/xxgk/zcfb/tz/202503/t20250318_1396627.html).
- [5] 谢人超, 胡珉昊, 唐琴琴, 等. 面向绿色计算的算网能一体化: 架构、关键问题与挑战[J]. 通信学报, 2025, 46(8): 205-224.
- Xie R C, Hu M H, Tang Q Q, et al. Computing-network-energy integration for green computing: architecture, key issues and challenges[J]. Journal on Communications, 2025, 46(8): 205-224.
- [6] 郭庆来, 陈敏, 王奕, 等. 算力电力协同: 思路与探索白皮书[M]. 北京: 清华大学, 北京火山引擎科技有限公司, 2025: 8.
- Guo Q L, Chen M, Wang Y, et al. Computing and power synergy: ideas and exploration white paper[M]. Beijing: Tsinghua University, Beijing Volcano Engine Technology Co., Ltd., 2025: 8.
- [7] 北京邮电大学, 紫金山实验室. 算电协同技术白皮书[EB/OL]. 南京: 第九届未来网络发展大会组委会, 2025-08[2026-06-30]. <https://www.gfnds.com/uploads/20250818/63c414d3d2082ded22487edace5ca3ed.pdf>. BEIJING UNIVERSITY OF POSTS AND TELECOMMUNICATIONS, PURPLE MOUNTAIN LABORATORIES. Computing and power synergy technology white paper[EB/OL]. Nanjing: Organizing Committee of the 9th Future Network Development Conference, 2025-08[2026-06-30]. <https://www.gfnds.com/uploads/20250818/63c414d3d2082ded22487edace5ca3ed.pdf>.
- [8] 邵子豪, 王志浩, 周晓茂, 等. 算电协同研究综述: 架构、关键技术与展望[J]. 通信学报, 2025, 46(10): 287-308.
- Shao Z H, Wang Z H, Zhou X M, et al. A survey on computing and power synergy: architecture, key technologies and prospects[J]. Journal on Communications, 2025, 46(10): 287-308.
- [9] Li X, Yu W, Ruiz R, et al. Energy-Aware Cloud Workflow Applications Scheduling With Geo-Distributed Data[J]. IEEE Transactions on Services Computing, 2022, 15(2): 891-903.
- [10] Wang S, Zhang H, Wu T, et al. Electricity cost minimization for multi-workflow allocation in geo-distributed data centers[J]. IEEE Transactions on Services Computing, 2025, 18(3): 1397-1410.
- [11] Radovanovic A, Koningstein R, Schneider I, et al. Carbon-Aware Computing for Datacenters[J]. IEEE Transactions on Power Systems, 2023, 38(2): 1270-1280.
- [12] Kumar M S, Gupta I, Panda S K, et al. Granularity-based workflow scheduling algorithm for cloud computing[J]. The Journal of Supercomputing, 2017, 73(12): 5440-5464.
- [13] Shui J, Peng D, Zeng H, et al. Optimal scheduling of multiple entities in virtual power plant based on the master-slave game[J]. Applied Energy, 2024, 376: 124286.
- [14] Flores-Quiroz A, Strunz K. A distributed computing framework for multi-stage stochastic planning of renewable power systems with energy storage as flexibility option[J]. Applied Energy, 2021, 291: 116736.
- [15] Xie Y, Gui F, Wang W, et al. A two-stage multi-population genetic algorithm with heuristics for workflow scheduling in heterogeneous distributed computing environments[J]. IEEE Transactions on Cloud Computing, 2023, 11(2): 1446-1460.
- [16] Zhang J, Cheng L, Liu C, et al. Cost-aware scheduling systems for real-time workflows in cloud: An approach based on genetic algorithm and deep reinforcement learning[J]. Expert Systems with Applications, 2023, 234: 120972.
- [17] Zhang H, Zhang Y, Wang S, et al. Electricity cost minimization for workflows scheduling in geo-distributed data centers[C]//Service Science: CCF 17th International Conference on Service Science (ICSS 2024), May 11-12, 2024, Hong Kong, China.
- [18] Thompson C C, Oikonomou P E K, Etemadi A H, et al. Optimization of data center battery storage investments for microgrid cost savings, emissions reduction, and reliability enhancement[J]. IEEE Transactions on Industry Applications, 2016, 52(3): 2053-2060.
- [19] Yang W, Qv H, Wei X, et al. Pricing temporal flexibility of data center jobs with heterogeneous time constraints[C]//2025 IEEE Industry Applications Society Annual Meeting (IAS), June 15-20, 2025, New Taipei City, Taiwan. IEEE, 2025: 1-6.
- [20] 丁巧宜, 王梓耀, 潘振宁, 等. 面向电量-调频-容量市场的数据中心园区算力及电力资源规划[J]. 电力系统自动化, 2024, 48(1): 59-66.
- Ding Z, Chen S, Sun Y, et al. Planning of computing and power resources for data center park oriented to energy-frequency-capacity market[J]. Automation of Electric Power Systems, 2024, 48(1): 59-66.
- [21] Ding Z, Chen S, Sun Y, et al. Multi-time-scale joint optimization of data center market transactions and computing resource allocation[J]. IEEE Transactions on Industry Applications, 2026, 62(2): 2112-2123.
- [22] Kim K, Yang F, Zavala V M, et al. Data centers as dispatchable loads to harness stranded power[J]. IEEE Transactions on Sustainable Energy, 2016, 8(1): 208-218.
- [23] Yang Z, Trivedi A, Ni M, et al. Distribution locational marginal pricing based equilibrium optimization strategy for data center park with spatial-temporal demand-side resources[J]. Journal of Modern Power Systems and Clean Energy, 2023, 11(6): 1959-1970.
- [24] Cioara T, Anghel I, Bertocini M, et al. Optimized flexibility management enacting data centres participation in smart demand response programs[J]. Future Generation Computer Systems, 2018, 78: 330-342.

- [25] Chen S, Jiao L, Liu F, et al. EdgeDR: An online mechanism design for demand response in edge clouds[J]. *IEEE Transactions on Parallel and Distributed Systems*, 2021, 33(2): 343-358.
- [26] Wu J K, Liu Z W, Li S, et al. Evolutionary decision-making mechanism for geo-distributed data center aggregation and VPP strategic pricing[J]. *IEEE Transactions on Consumer Electronics*, 2026, 72(2): 4058-4069.
- [27] Topcuoglu H, Hariri S, Wu M Y. Performance-effective and low-complexity task scheduling for heterogeneous computing[J]. *IEEE Transactions on Parallel and Distributed Systems*, 2002, 13(3): 260-274.
- [28] Durillo J J, Prodan R. Multi-objective workflow scheduling in Amazon EC2[J]. *Cluster Computing*, 2014, 17(2): 169-189.
- [29] Wang Z J, Zhan Z H, Yu W J, et al. Dynamic Group Learning Distributed Particle Swarm Optimization for Large-Scale Optimization and Its Application in Cloud Workflow Scheduling[J]. *IEEE Transactions on Cybernetics*, 2020, 50(6): 2715 - 2729.
- [30] Li H, Chen B, Huang J, et al. Mutation-driven and population grouping PRO algorithm for scheduling budget-constrained workflows in the cloud[J]. *Cluster Computing*, 2024, 27(1): 1137 - 1158.
- [31] Chen Z G, Zhan Z H, Lin Y, et al. Multiobjective Cloud Workflow Scheduling: A Multiple Populations Ant Colony System Approach[J]. *IEEE Transactions on Cybernetics*, 2019, 49(8): 2912 - 2926.
- [32] Li H, Chen B, Huang J, et al. Clustering-assisted gradient-based optimizer for scheduling parallel cloud workflows with budget constraints [J]. *The Journal of Supercomputing*, 2024, 80(12): 17097 - 17134.
- [33] Chakravarthi K K, Neelakantan P, Shyamala L, et al. Reliable budget aware workflow scheduling strategy on multi-cloud environment[J]. *Cluster Computing*, 2022, 25(2): 1189-1205.
- [34] Mohammadzadeh A, Masdari M. Scientific workflow scheduling in multi-cloud computing using a hybrid multi-objective optimization algorithm[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2023, 14(4): 3509-3529.
- [35] Dong T, Xue F, Xiao C, et al. Workflow scheduling based on deep reinforcement learning in the cloud environment[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2021, 12(12): 10823-10835.
- [36] Li H, Huang J, Wang B, et al. Weighted double deep Q-network based reinforcement learning for bi-objective multi-workflow scheduling in the cloud[J]. *Cluster Computing*, 2022, 25(2): 751 - 768.
- [37] Yan J, Huang Y, Gupta A, et al. Energy-aware systems for real-time job scheduling in cloud data centers: A deep reinforcement learning approach[J]. *Computers and Electrical Engineering*, 2022, 99: 107688.
- [38] Hussain M, Wei L, Lakhani A, et al. Energy and performance-efficient task scheduling in heterogeneous virtualized cloud computing[J]. *Sustainable Computing: Informatics and Systems*, 2021, 30: 100517.
- [39] Li X, Wang J, Shi K, et al. Energy-cost-driven scheduling scheme for data centers incorporating job dependency constraints[J]. *IEEE Transactions on Industry Applications*, 2025, 61(4): 5420-5429.
- [40] Liu W, Yan Y, Sun Y, et al. Online job scheduling scheme for low-carbon data center operation: An information and energy nexus perspective[J]. *Applied Energy*, 2023, 338: 120918.
- [41] Maray M, Mustafa E, Shuja J, et al. Dependent task offloading with deadline-aware scheduling in mobile edge networks[J]. *Internet of Things*, 2023, 23: 100868.
- [42] Zhou Y, Li X, Luo J, et al. Learning to optimize DAG scheduling in heterogeneous environment[C]//2022 23rd IEEE International Conference on Mobile Data Management (MDM), June 6-9, 2022, Paphos, Cyprus. IEEE, 2022: 137-146.
- [43] Song Y, Li C, Tian L, et al. A reinforcement learning based job scheduling algorithm for heterogeneous computing environment[J]. *Computers and Electrical Engineering*, 2023, 107: 108653.
- [44] Fan X, Weber W D, Barroso L A. Power provisioning for a warehouse-sized computer[J]. *ACM SIGARCH Computer Architecture News*, 2007, 35(2): 13-23.
- [45] 张显, 谢开, 张晓静, 等. 算力电力协同视角下的电力市场演进思路与关键技术[J/OL]. *电力系统自动化*, 2025[2025-12-23]. <https://link.cnki.net/urlid/32.1180.TP.20251219.1527.003>.  
Zhang X, Xie K, Zhang X J, et al. Evolutionary ideas and key technologies of power market from the perspective of computing and power synergy[J/OL]. *Automation of Electric Power Systems*, 2025[2025-12-23]. <https://link.cnki.net/urlid/32.1180.TP.20251219.1527.003>.
- [46] Schäfer M, Cerdas F, Herrmann C. Towards Standardized Grid Emission Factors: Methodological Insights and Best Practices[J]. *Energy & Environmental Science*, 2024, 17(8): 2776-2786.
- [47] Hu W, Liu B, Gomes J, et al. Strategies for pre-training graph neural networks[C]//8th International Conference on Learning Representations (ICLR 2020), April 26-30, 2020, Addis Ababa, Ethiopia. OpenReview.net, 2020.
- [48] Wang Y, He H, Tan X. Truly proximal policy optimization[C]//Proceedings of the Thirty-Fifth Conference on Uncertainty in Artificial Intelligence (UAI 2019), July 22-25, 2019, Tel Aviv, Israel. Proceedings of Machine Learning Research, 2020, 115: 113-122.
- [49] Calheiros R N, Ranjan R, Beloglazov A, et al. CloudSim: A toolkit for modeling and simulation of cloud computing environments and evaluation of resource provisioning algorithms[J]. *Software: Practice and Experience*, 2011, 41(1): 23-50.
- [50] SPEC. SPECpower\_ssj 2008 Results[EB/OL]. [2025-08-15]. [https://www.spec.org/power\\_ssj2008/results/](https://www.spec.org/power_ssj2008/results/).
- [51] Electricity Maps. Carbon intensity[EB/OL]. [2025-09-10]. <https://app.electricitymaps.com/zone/US-NW-PACE>.
- [52] Deelman E, Vahi K, Juve G, et al. Pegasus: a workflow management system for science automation[J]. *Future Generation Computer Systems*, 2015, 46: 17-35.
- [53] Juve G, Chervenak A, Deelman E, et al. Characterizing and profiling scientific workflows[J]. *Future Generation Computer Systems*, 2013, 29(3): 682 - 692.
- [54] Newman M E J, Strogatz S H, Watts D J. Random graphs with arbitrary degree distributions and their applications[J]. *Physical Review E*, 2001, 64(2): 026118.
- [55] Kumar M, Sharma S, Goel A, et al. A comprehensive survey for scheduling techniques in cloud computing[J]. *Journal of Network and Computer Applications*, 2019, 143: 1-33.
- [56] Li H, Xu G, Chen B, et al. Dual-mutation mechanism-driven snake optimizer for scheduling multiple budget constrained workflows in the cloud[J]. *Applied Soft Computing*, 2023, 149: 110966.



王梓屹（2002- ），男，北京邮电大学博士研究生，主要研究方向为电算协同系统调度优化。

元峰（1971- ），男，北京邮电大学教授、博士生导师，主要研究方向为通信软件。



郭少勇（1985- ），男，博士，北京邮电大学教授、博士生导师，主要研究方向为工业互联网网络管控、电力物联网等。



陈洁蔚（1997- ），女，博士，北京邮电大学博士后，主要研究方向为分布式智能、算力网络。



肖轶涛（2001- ），男，北京邮电大学博士研究生，主要研究方向为网络管控、多智能体系统和边缘计算。



张子昊（1996- ），男，南网数研院电算工程公司工程师，研究方向为新能源运行、控制、新型电力系统数字化。  
 蔡田田（1982- ），女，南方电网数字电网研究院股份有限公司正高级工程师，主要研究方向：电网数字化技术。