计及节点关联与长期影响的跨区域算电协同调度方法研究

刘蒙[1]，杜丽艳[1]，孟兵[2]，张鹏[1]，张蕾[2]，李梁[1]
（1. 国网冀北电力有限公司，北京 100052；2. 国网冀北电力有限公司张家口供电公司，河北 张家口 075000）

摘　要：针对跨区域多数据中心调度中候选节点关联信息利用不足、当前部署决策难以反映后续资源竞争与能源状态变化的问题，提出一种计及节点关联与长期影响的跨区域算电协同调度方法。首先，构建任务条件边感知候选图，通过边条件消息传递融合候选数据中心的算力、能源及网络关联信息；其次，采用滚动优化生成候选动作的条件长期代价，并以此监督图模型学习当前部署动作对后续调度的影响；最后，结合硬约束筛选与长期代价排序生成可行调度方案。实验结果表明，相较无调度策略，所提方法的购电成本、碳排放和区域峰值负荷分别降低 5.34%、6.28% 和 5.84%，新能源消纳率达到 99.55%，验证所提方法在跨区域算电协同场景下的有效性。

关键词：跨区域多数据中心；算电协同调度；节点关联；长期优化；任务迁移；新能源消纳
中图分类号：TM73
文献标志码：A
doi：10.11959/j.issn.2096−3750.

Research on cross-regional computing-electricity collaborative scheduling considering node relationships and long-term impacts

LIU Meng[1], DU Liyan[1], MENG Bing[2], ZHANG Peng[1], ZHANG Lei[2], LI Liang[1]
1. State Grid Jibei Electric Power Company Limited, Beijing 100052, China
2. State Grid Jibei Electric Power Company Limited, Zhangjiakou Power Supply Company, Zhangjiakou 075000, China

Abstract: To address the insufficient utilization of candidate-node correlations and the inability of current deployment decisions to capture subsequent resource competition and changes in energy conditions in cross-region multi-datacenter scheduling, this paper proposes a cross-region computing-power and electricity collaborative scheduling method that accounts for node correlations and long-term impacts. First, a task-conditioned, edge-aware candidate graph is constructed, and edge-conditioned message passing is employed to integrate computing resource, energy, and network correlation information among candidate datacenters. Second, rolling-optimization is used to generate the conditional long-term cost of candidate actions, which serves as supervision for training the graph model to learn the impacts of current deployment decisions on subsequent scheduling. Finally, feasible scheduling decisions are generated by combining hard-constraint filtering with long-term cost-based candidate ranking. Experimental results show that, compared with the no-scheduling baseline, the proposed method reduces electricity procurement cost, carbon emissions, and regional peak load by 5.34%, 6.28%, and 5.84%, respectively, while achieving a renewable energy consumption rate of 99.55%. These results demonstrate the effectiveness of the proposed method in cross-region computing-power and electricity collaborative scheduling scenarios.

Key words: cross-regional multi-data-center systems, computing-electricity collaborative scheduling, node relationship, long-term optimization, task migration, renewable energy utilization

收稿日期：XXXX−XX−XX；**修回日期：**XXXX−XX−XX
通信作者：刘蒙，liumeng.0401@163.com
基金项目：国网冀北电力有限公司科技项目（No.B3010725Z005）
Foundation Items: This work is supported by the Science and Technology Project of State Grid Jibei Electric Power Company Limited (No.B3010725Z005)

0 引言

随着人工智能训练、在线推理和批处理分析等云服务持续增长，地理分布式数据中心逐渐成为重要的算力基础设施[1]。而由于不同区域在算力资源、网络条件、电价及新能源出力等方面存在时空差异，使得计算任务的部署位置会影响计算效率、网络开销与能源成本[2]。因此，如何综合利用区域间的算力与能源差异，实现跨区域多数据中心任务的合理调度，成为算力网络与新型电力系统交叉领域的重要研究问题[3-4]。

现有研究主要从任务部署评价、调度策略学习和不确定性优化等方面展开。基于优化模型和启发式规则的方法通常依据资源利用率、电价、新能源供给及网络条件评价候选位置[5-8]，但其决策效果依赖评价函数以及当前状态信息[9-11]；深度强化学习[12]及基于DDPG[13]等算法的调度方法通过状态、动作与奖励交互学习部署策略，但其所设状态向量难以充分表达候选数据中心之间的结构关系，单步奖励也难以反映当前部署对后续调度的影响；随机优化[14]和分布鲁棒优化[15-17]则主要针对新能源出力和计算负荷的不确定性，通过随机场景建模或不确定分布集合来进一步提升调度决策的鲁棒性。然而，上述方法仍存在两个不足：其一，基于单节点状态或静态特征的候选评价，难以充分利用节点间的区域与网络关联信息；其二，依据当前状态或单步物理代价的决策机制，难以反映任务部署对后续资源竞争、能源利用及区域负荷的影响。

针对上述问题，图注意力网络及边信息驱动的消息传递机制能够融合候选数据中心的节点特征与关联信息，为候选部署位置的结构化建模提供支持[18-20]；但现有图建模通常侧重节点的即时状态及静态关系，难以直接描述特定部署动作对后续调度的影响[21-23]。滚动优化能够通过求解有限未来窗口评估当前决策对后续状态的影响，为任务部署提供前瞻性信息[24-26]。然而在在线阶段，针对每个候选位置逐一执行滚动优化会带来较大计算开销，并且仅依据当前时刻物理代价进行监督，又难以体现不同部署动作的长期影响[27-30]。因此，如何利用未来窗口综合代价来描述候选动作的长期收益，是跨区域算电协同调度需要解决的问题。

基于上述分析，本文提出一种计及节点关联与长期影响的跨区域算电协同调度方法ROSE-GAT（Rolling Optimization-Supervised Edge-aware Graph Attention Network）。首先，构建任务条件边感知候选图，以候选数据中心为节点，以原位置至候选位置的部署关系为动作边，以候选间区域与网络关联为关系边，通过边条件消息传递融合候选自身状态及关联信息；其次，采用滚动优化分别固定各候选动作并计算条件长期代价，将其作为图模型的监督信号，学习当前物理代价与后续综合调度代价之间的差异；最后，在线阶段通过资源、供电及服务约束进行硬约束筛选，并依据预测长期代价对可行候选排序，以兼顾调度可行性、决策效率与长期算电协同收益。

本文的主要工作如下：

1. 针对单节点状态难以充分反映节点间的区域与网络关联信息的问题，本文构建任务条件边感知候选图。将原数据中心至候选数据中心的部署关系表示为动作边，将候选数据中心间的区域和网络关联表示为关系边，利用边条件消息传递进行联合建模。

2. 针对仅依据当前状态进行决策难以充分反映任务部署对后续资源竞争、能源利用及区域负荷的影响的问题，本文构建滚动优化监督框架。通过固定焦点任务的不同可行候选动作，分别求解滚动窗口内的优化问题，以窗口综合代价构造监督标签，学习当前动作的长期影响。

3. 提出计及节点关联与长期影响的跨区域算电协同调度方法。通过离线生成长期监督样本、在线通过图模型预测与排序候选动作，并结合硬约束筛选，确保调度决策满足资源、区域供电等约束。

1 系统建模

如图1所示，本文研究由多个跨区域地理分布式数据中心构成的统一算力资源池，各数据中心通过广域网络互联，并由区域新能源和电网共同供电，新能源优先满足本地需求，不足部分由电网补充。下面分别建立任务部署、数据中心用能、网络服务和调度模型。

1.1 任务部署模型

设时间槽、数据中心、区域和资源类型集合分别为T、D、$\mathcal{R}$和$\mathcal{K}=\{\text{cmp,cpu,gpu,mem}\}$，数据中心$j$所属区域记为$\rho(j)$。任务集合记为$\mathcal{Q}$。任务$i$由

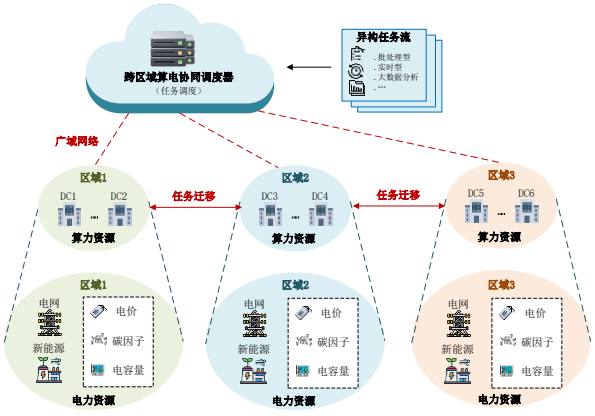

图1　跨区域多数据中心算电协同任务调度场景

到达时间 a_i、持续时间 d_i、多维资源需求 $\mathbf{c}_i = (c_i^k)_{k\in\mathcal{K}}$、迁移数据量 b_i、截止时间 f_i、最大允许时延 s_i、优先级 p_i、任务类型 v_i 和原数据中心 o_i 描述。

为表示任务的接纳状态和部署位置，令 x_{ij} 表示任务 i 是否部署到数据中心 j，r_i 表示是否拒绝该任务，则任务的唯一部署关系为：

$$\sum_{j\in\mathcal{D}} x_{ij} + r_i = 1 \tag{1}$$

其中 $x_{ij}, r_i \in \{0,1\}$，且 $x_{ij}=1$ 表示任务 i 部署至数据中心 j，$r_i=1$ 表示任务 i 被拒绝。本文根据任务服务需求，将实时性要求高或存在安全限制的任务设置为不可迁移任务，其余任务允许跨区域迁移。对于不可迁移任务，其候选动作仅保留，即 $j=o_i$；若该候选同样不满足约束，则拒绝任务。

为控制调度模型的复杂度，本文采用单次部署假设：任务完成初始部署后即开始执行，执行期间不再进行二次迁移，并在整个执行区间内持续占用相应资源。令 $I_i^t = \mathbb{I}(a_i \leqslant t < a_i + d_i)$ 表示任务 i 在时间槽 t 的活动状态，则数据中心 j 在时间槽 t 的第 k 类资源负载为：

$$L_{j,t}^k = \sum_i x_{ij} I_i^t c_i^k \tag{2}$$

其中，对于任意数据中心 j、时间槽 t 和资源类型 k，应满足 $L_{j,t}^k \leqslant \eta^{res} C_j^k$，$C_j^k$ 为数据中心 j 的第 k 类资源容量，η^{res} 为资源安全系数。

进一步地，将 $u_{j,t}^k = L_{j,t}^k / C_j^k$ 定义为第 k 类资源的利用率。本文以综合算力利用率 $u_{j,t}^{cmp}$ 表征功耗模型中的IT负载，即 $u_{j,t}^{eff} = u_{j,t}^{cmp}$；CPU、GPU和内存利用率分别用于容量约束和候选特征构造。

调度过程中按照任务到达顺序更新资源状态，并在任务执行周期内持续检查资源约束，保证候选动作满足完整执行周期要求。

1.2　数据中心用能模型

本文关注任务调度引起的数据中心整体能耗变化，因此采用数据中心综合算力利用率 $u_{j,t}^{cmp}$ 表征数据中心 j 在时间槽 t 的IT负载，CPU、GPU和内存等资源仍依据式（2）分别进行容量约束检查，不再通过经验权重合成为功耗利用率。设 P_j^{idle} 和 P_j^{full} 分别表示数据中心 j 的IT设备空闲功率和满载功率，则IT功率为：

$$P_{j,t}^{IT} = P_j^{idle} + \left(P_j^{full} - P_j^{idle}\right) u_{j,t}^{cmp} \tag{3}$$

计及辅助设施能耗后，数据中心总功率为 $P_{j,t}^{DC} = PUE_j P_{j,t}^{IT}$，将同一区域内数据中心功率进行汇总，得到：

$$P_{r,t}^{DC} = \sum_{j:\rho(j)=r} P_{j,t}^{DC} \tag{4}$$

设 $\hat{G}_{r,t}$ 为区域 r 在时间槽 t 的新能源预测功率，新能源优先满足数据中心负荷，不足部分由电网补充，则购电功率为：

$$P_{r,t}^{buy} = [\,P_{r,t}^{DC} - \hat{G}_{r,t}\,]^+ \tag{5}$$

其中 $[x]^+ = \max(x,0)$。新能源消纳功率为 $\min(P_{r,t}^{DC}, \hat{G}_{r,t})$，新能源弃用功率为 $[\hat{G}_{r,t} - P_{r,t}^{DC}]^+$。分时电价 $\pi_{r,t}$ 和碳因子 $\kappa_{r,t}$ 分别用于计算购电成本和碳排放。

考虑区域原有基础负荷 $P_{r,t}^{base}$，区域总电网负荷及供电约束为：

$$P_{r,t}^{grid} = P_{r,t}^{base} + P_{r,t}^{buy} \leqslant \eta^{grid} C_{r,t}^{grid} \tag{6}$$

其中，$C_{r,t}^{grid}$ 表示区域供电容量，η^{grid} 表示电网供电安全系数。

此外，为描述不同区域的能源运行差异，定义区域算电状态向量：

$$\mathbf{s}_{r,t}^{ce} = [\,\tilde{\pi}_{r,t}, \tilde{\kappa}_{r,t}, s_{r,t}^{re}, s_{r,t}^{grid}\,]^{\mathrm{T}} \tag{7}$$

其中，$\tilde{\pi}_{r,t}$ 和 $\tilde{\kappa}_{r,t}$ 分别表示归一化后的电价和碳因子；将 $s_{r,t}^{re} = [\,\hat{G}_{r,t} - P_{r,t}^{DC}\,]^+ / \max(\hat{G}_{r,t}, 1)$ 定义为新能源裕度，用于表征当前新能源供给相对于数据中心负荷的剩余程度；区域电网负荷水平定义为 $s_{r,t}^{grid} = P_{r,t}^{grid} / C_{r,t}^{grid}$，用于表征区域供电容量的占用程度。该状态用于构造候选节点能源特征，并根据部署前后状态变化计算增量电费、碳排放和新能源利用收益。

1.3　网络服务模型

跨区域任务部署涉及数据传输时延和网络传输能耗。为区分区域内部和跨区域动作，定义跨区域指示量：

$$\gamma_{ij} = \mathbb{I}\left(\rho(o_i) \neq \rho(j)\right) \tag{8}$$

其中，$\gamma_{ij} = 1$ 表示任务 i 由原数据中心 o_i 部署至其他区域的数据中心 j，否则表示原地部署或区域内部部署。

设原数据中心 o_i 至候选数据中心 j 的可用带宽为 $B_{o_i,j}$，往返时延为 $l_{o_i,j}$，则任务 i 的迁移时间为：

$$\tau_{ij}^{mig} = \mathbb{I}(j \neq o_i)\left(\frac{8b_i}{B_{o_i,j}} + \frac{l_{o_i,j}}{1000}\right) \tag{9}$$

其中，b_i 为 1.1 节定义的任务迁移数据量。原地部署不产生迁移时间和网络能耗；迁移部署则需要根据相应链路带宽和往返时延计算迁移时间。设 ε_j^{net} 为数据中心 j 的单位网络传输能耗，则任务 i 由原数据中心 o_i 迁移至候选数据中心 j 时的网络能耗为 $E_{ij}^{net} = b_i(\varepsilon_{o_i}^{net} + \varepsilon_j^{net})/2$；当 $j = o_i$ 时，$E_{ij}^{net} = 0$。

任务部署后的服务时延由候选数据中心排队时延和网络迁移时延共同构成，并要求预测服务时延不超过最大允许时延 s_i，同时满足任务截止时间 f_i。上述网络服务约束与 1.1 节的多维资源约束、1.2 节的供电约束共同用于候选动作筛选。令 M_{ij} 表示任务 i 部署至数据中心 j 时上述各项约束的综合检查结果，则可行候选集合为：

$$A_i = \left\{ j \in \mathcal{D} \middle| M_{ij} = 1 \right\} \tag{10}$$

其中，若 A_i 为空，则任务 i 被拒绝；否则后续滚动优化和图模型均仅在 A_i 内进行候选评价，从而保证最终调度动作满足物理约束。

1.4　调度问题模型

对于任务 i 的任一可行候选数据中心 $j \in A_i$，根据任务部署前后的系统状态变化，计算增量购电成本、增量碳排放、新能源消纳增量、迁移网络能耗、资源负载惩罚和区域峰值惩罚，来构成候选动作代价向量：

$$\mathbf{g}_{ij} = [\,C_{ij}^{elec}, C_{ij}^{carb}, -E_{ij}^{re}, E_{ij}^{net}, L_{ij}^{bal}, P_{ij}^{peak}\,]^{\mathrm{T}} \tag{11}$$

其中，购电成本 C_{ij}^{elec} 和碳排放 C_{ij}^{carb} 根据 1.2 节中任务部署引起的增量购电量以及对应区域的分时电价和碳因子计算；新能源消纳增量 E_{ij}^{re} 采用负号，使新能源利用增加能够降低候选动作代价；迁移网络能耗 E_{ij}^{net} 根据 1.3 节的迁移数据量和链路条件计算；资源负载 L_{ij}^{bal} 和区域峰值 P_{ij}^{peak} 则分别用于抑制任务过度集中和区域负荷峰值。

由于不同目标分量量纲不同，对各分量进行归一化处理。设 ξ_m 为第 m 个目标分量的归一化尺度，$\mathbf{w}$ 为多目标权重向量，则候选动作的物理综合代价定义为:

$$c_{ij}^{phy} = \sum_{m=1}^{6} w_m \frac{g_{ij}^m}{\xi_m} \tag{12}$$

其中，$\mathbf{w}$ 用于衡量各归一化目标分量在综合代价中的相对重要性。不同的权重配置会改变各目标对综合代价的贡献，进而影响候选调度动作的代价排序及最终的任务部署决策，具体影响将在仿真实验章节通过权重敏感性实验分析。

由于本文假设当任务不存在可行候选时允许拒绝任务。故为降低高优先级任务被拒绝的概率，定义任务 i 的拒绝代价为：

$$C_i^{rej} = \lambda_0 + \lambda_p p_i \tag{13}$$

其中，λ_0 和 λ_p 分别为基础拒绝惩罚和优先级惩罚系数，p_i 为 1.1 节定义的任务优先级。

由此，任务序列的综合调度目标为：

$$J = \min\left(\sum_{i \in \mathcal{Q}}\sum_{j \in A_i} x_{ij} c_{ij}^{phy} + \sum_{i \in \mathcal{Q}} r_i C_i^{rej}\right) \tag{14}$$

式（14）以综合物理代价和任务拒绝代价之和最小为目标，并满足式（1）的唯一部署约束、式（10）的可行性条件及资源、供电和服务约束，从而统一描述计算、电力、新能源、网络和区域负荷之间的耦合关系。

2　跨区域的算电协同调度方法

针对跨区域多数据中心调度中候选数据中心之间算力、能源与网络关系难以充分表达，以及当前部署决策难以反映后续资源竞争和能源状态变化的问题，本文提出分为离线和在线两阶段的算电协同调度方法，其整体流程如图 2 所示。从图中可以看出，ROSE-GAT 整体包括滚动优化监督、边感知候选图构建、边条件消息传递、图模型训练和在线调度决策五部分。下面将分别详细展开介绍。

2.1　滚动优化监督

为评价当前部署对后续资源竞争和能源状态的影响，采用滚动优化生成候选级长期监督信息。设第 t 时刻的当前任务 i 为焦点任务，滚动窗口记为 $\mathcal{H}_t = t, \cdots, t + H - 1$，窗口内任务集合为 $\mathcal{Q}_t^H$。令 $F_t(\mathbf{x},\mathbf{r})$ 表示式（14）在滚动窗口内的综合调度目标，则滚动优化问题为：

$$J_t^{RH} = \min_{(\mathbf{x},\mathbf{r}) \in \Omega_t^H} F_t(\mathbf{x},\mathbf{r}) \tag{15}$$

其中，Ω_t^H 表示由任务部署、资源、供电和服务等

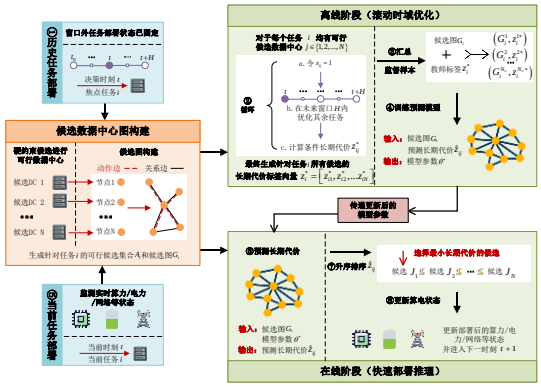

图2　ROSE-GAT的整体框架流程图

级协议等约束构成的窗口可行域。

对于焦点任务的每个可行候选动作$j \in A_i$，固定其部署位置$x_{ij}=1$，并重新求解滚动优化问题，得到候选动作的条件长期代价：

$$Q_i^{RH}(j)=\min_{(\mathbf{x},\mathbf{r})\in\Omega_i^H,x_{ij}=1}F_t(\mathbf{x},\mathbf{r}) \tag{16}$$

其中$Q_i^{RH}(j)$表示任务i选择候选数据中心j后，在给定滑动窗口内产生的综合调度代价。该代价既反映当前部署产生的即时效果，也能够量化其对后续任务可部署空间、资源竞争及能源利用状态的影响。通过比较同一焦点任务不同可行候选动作的条件长期代价，可以获得反映候选动作相对优劣的监督信息。为减小不同任务之间的数值尺度差异，进一步对同一任务下各候选动作的条件长期代价$Q_i^{RH}(j)$及物理代价c_{ij}^{phy}分别进行候选内标准化，得到教师标签z_{ij}和标准化物理代价$\tilde{c}_{ij}^{phy}$，用于后续图模型训练。

从式（16）可以看出，与仅依据当前状态或单步物理代价评价候选动作的方法相比，滚动优化监督机制将有限未来窗口内的调度结果纳入候选评价，为模型学习当前部署决策的长期影响提供前瞻性监督。需要指出的是，条件长期代价是基于给定滚动窗口和优化模型得到的有限时域评价，并不代表对无限未来收益的精确估计。

2.2　边感知候选图

对于焦点任务i，根据式（10）得到可行候选集合A_i，并构建任务条件边感知候选图：

$$G_i=(A_i,\mathcal{E}_i^a,\mathcal{E}_i^r) \tag{17}$$

其中，$\mathcal{E}_i^a$表示任务原数据中心o_i至各候选数据中心的动作边集合，$\mathcal{E}_i^r$表示候选数据中心之间的有向关系边集合。动作边描述焦点任务从原数据中心部署至候选数据中心的具体部署关系，用于表征当前任务与候选部署位置之间的联系；关系边描述不同候选数据中心之间的区域归属及网络连接特征，用于描述候选节点之间的关联。前者建立焦点任务与候选动作的对应关系，后者通过候选节点间的信息交互补充单个候选节点自身状态难以表达的关联信息。

候选节点特征由数据中心当前资源状态、候选部署后的资源状态估计以及区域算电状态构成；任务特征由1.1节定义的任务属性构成；动作边特征用于描述原地部署、区域内迁移和跨区域迁移对应的部署关系及网络状态；候选间关系边特征表示为：

$$\mathbf{e}_{jk}^{r,i}=[\,I_{jk}^{same},I_{jk}^{cross},\tilde{B}_{jk},\tilde{l}_{jk},\tilde{\tau}_{jk}^{mig,i},\tilde{E}_{jk}^{net,i}\,]^{\mathrm{T}} \tag{18}$$

其中，I_{jk}^{same}和I_{jk}^{cross}分别表示候选j与k是否属于同一区域和跨区域；后四项分别为归一化后的链路带宽、往返时延，以及按照1.3节相同方法计算并归一化后的任务条件迁移时间和网络能耗。

2.3　边条件消息传递

候选图构建完成后，将候选节点特征、任务特征和原数据中心至候选的动作边特征进行联合编码，得到任务i条件下候选j的初始表示：

$$\mathbf{h}_{ij}^{(0)}=\sigma\left(\mathbf{W}_n\mathbf{f}_{ij}^{n}+\mathbf{W}_t\mathbf{f}_i^{task}+\mathbf{W}_a\mathbf{e}_{ij}^{a}\right) \tag{19}$$

其中，$\mathbf{f}_{ij}^{n}$、$\mathbf{f}_i^{task}$和$\mathbf{e}_{ij}^{a}$分别表示候选节点、任务和动作边特征；$\mathbf{W}_n$、$\mathbf{W}_t$和$\mathbf{W}_a$分别为候选节点特征、任务特征和动作边特征的可学习映射矩阵，$\sigma(\cdot)$表示非线性激活函数。式（19）通过联合编码候选节点特征、焦点任务特征和动作边特征，形成任务条件下的候选初始表示。该表示同时包含候选数据中心的资源与能源状态、当前任务属性以及选择该候选位置对应的部署关系，使后续候选评价能够结合任务需求和候选动作的具体条件展开。

对于关系边$j'\to j$，将发送候选j'、接收候选j及2.2节定义的关系边特征$\mathbf{e}_{j'j}^{r,i}$共同编码为$\mathbf{z}_{ij'j}$，并计算边条件注意力得分：

$$q_{ij'j}=\mathrm{LeakyReLU}\,(\mathbf{a}^{\mathrm{T}}\mathbf{z}_{ij'j}) \tag{20}$$

其中，$\mathbf{z}_{ij'j}$由$\mathbf{h}_{ij}^{(0)}$、$\mathbf{h}_{ij'}^{(0)}$和$\mathbf{e}_{j'j}^{r,i}$经线性映射后拼接得到，$\mathbf{a}$为可学习注意力参数。

随后在候选j的邻域$\mathcal{N}_i(j)$内对注意力得分进行归一化：

$$\alpha_{ij'j}=\frac{\exp\,(q_{ij'j}/T_{\mathrm{att}})}{\sum_{d\in\mathcal{N}_i(j)}\exp\,(q_{idj}/T_{\mathrm{att}})} \tag{21}$$

其中，T_{att}为注意力温度系数，$\alpha_{ij'j}$表示发送候选j'对接收候选j的信息贡献程度。进一步聚合邻域信息，得到接收候选j的更新表示：

$$\mathbf{h}_{ij}^{(1)}=\phi\left(\mathbf{h}_{ij}^{(0)},\sum_{j'\in\mathcal{N}_i(j)}\alpha_{ij'j}\psi\left(\mathbf{h}_{ij'}^{(0)},\mathbf{e}_{j'j}^{r,i}\right)\right) \tag{22}$$

其中，$\psi(\cdot)$和$\phi(\cdot)$分别用于生成边条件邻域消息和更新候选表示，参数均通过模型训练获得。

由式（20）到式（22）可知，模型通过融合候选节点特征与关系边特征计算注意力权重，并加权聚合邻域信息，更新候选节点表示。其中，区域归属、链路带宽和往返时延等特征用于描述候选数据中心之间的区域与网络关联，任务条件迁移时间和网络能耗则反映相应的迁移代价。最终，模型基于更新后的候选表示预测各候选动作的长期代价，实现候选动作排序。其中，动作边描述焦点任务与候选部署位置之间的联系，关系边通过消息传递融合候选数据中心之间的关联信息。

2.4　图模型训练

经过边条件消息传递后，候选j获得融合其他候选关系信息的表示$\mathbf{h}_{ij}^{(1)}$。模型以标准化物理综合代价$\tilde{c}_{ij}^{phy}$为基准，预测长期代价修正量，得到候选动作的长期代价预测值：

$$\hat{z}_{ij}=\tilde{c}_{ij}^{phy}+f_\theta\left(\mathbf{h}_{ij}^{(1)}\right) \tag{23}$$

其中，$f_\theta(\cdot)$代表参数为θ的预测网络，$\hat{z}_{ij}$对应2.1节中的教师标签z_{ij}。本文不直接从候选节点特征回归完整的条件长期代价，而是以当前物理综合代价作为基准，利用图模型预测条件长期代价相对于该基准的修正量。

为兼顾长期代价预测精度和候选排序能力，训练损失定义为：

$$\mathcal{L}=\mathcal{L}_{\text{MSE}}+\lambda_r\mathcal{L}_{\text{rank}}+\lambda_2|\theta|_2^2 \tag{24}$$

其中，$\mathcal{L}_{\text{MSE}}$衡量预测值$\hat{z}_{ij}$与教师标签z_{ij}之间的误差，$\mathcal{L}_{\text{rank}}$用于约束同一任务不同候选之间的相对排序，$\lambda_r$和$\lambda_2$为相应权重。

2.5　在线调度决策

在线阶段在可行候选集合A_i上构建任务条件候选图，并根据训练后的ROSE-GAT预测各候选的长期代价，选择预测最小的候选：

$$j_i^*=\arg\min_{j\in A_i}\hat{z}_{ij} \tag{25}$$

其中，j_i^*表示任务i的最优候选数据中心。

为避免低收益迁移，设迁移收益阈值为δ。当原数据中心o_i仍满足约束时，进一步比较原地部署与候选迁移方案的预测长期代价。以原地部署的预测长期代价为基准，计算候选迁移动作的相对代价改善率，并将其与迁移收益阈值δ比较。仅当候选迁移方案的相对代价改善值超过阈值时，即$\hat{z}_{io_i}-\hat{z}_{ij_i^*}>\delta$，才执行迁移；否则保持原部署。若原数据中心不可行，则在满足硬约束的候选方案中选择预测长期代价最低的动作。本轮所有到达任务完成部署后，更新系统状态并进入下一轮调度。

3　仿真测试结果分析

为验证所提跨区域算电协同调度方法ROSE-GAT的有效性，本文基于项目数据和公开集群任务轨迹构建跨区域多数据中心仿真场景，并设置多种典型调度方法进行对比。实验从综合调度性能、资源利用与任务迁移行为等方面分析调度效果，并通过目标权重敏感性、迁移收益阈值敏感性和消融实验，进一步考察参数设置及关键模块对调度结果的影响。

3.1　实验设置

设置主要包括实验数据、实验参数、对比方法、评价指标，具体设置如下。

实验数据 本文基于Python环境构建跨区域多数据中心算电协同调度仿真场景，选取廊坊和张家口两个区域的8个数据中心作为调度对象，其中廊坊3个、张家口5个。数据中心的算力资源、电力参数和网络参数依据项目数据与公开资料构建，并按照统一的仿真尺度进行处理。任务数据由Google集群轨迹、MLaaS异构任务轨迹和Alibaba集群轨迹映射生成[31-32]，并根据任务属性和服务需求划分为批处理任务、训练任务和实时任务。实验分别构建训练集、验证集和测试集，对应包含5、2和1个任务流，每个任务流包含247个任务。调度周期将一天划分为24个连续的1h时间槽。基础实验场景的目标负载率和新能源渗透率均设置为50%，用于模拟算力资源竞争与新能源消纳需求并存的运行环境。训练和在线调度阶段均采用新能源出力预测值（由最多4个历史时间槽的因果滑动均值获得）；实际新能源出力仅用于最终结果评价，以避免引入未来信息。

实验参数 ROSE-GAT采用单层单头边感知图注意力网络，隐藏层维度设为16。候选节点、任

务、动作边和关系边的特征维度分别为19、14、8和6，分别表征数据中心状态与区域算电条件、任务资源与服务需求、候选部署的网络迁移代价以及数据中心间的区域与网络关联。特征选取对应资源状态、任务需求、部署代价和节点关联四类决策信息，以支持候选部署方案的综合评价。滚动窗口长度设为4个时间槽，候选数据中心数量上限为6，以兼顾未来状态感知、在线比较规模与优化开销。资源安全系数和电网安全系数分别设为0.90和0.92，注意力温度设为1.00，迁移收益阈值设为0.035。

对比方法 本文设置无调度、轮询调度、负载均衡、新能源优先、贪心调度和滚动优化六种对比方法。其中，无调度作为基础参照，轮询调度按预设顺序分配任务，负载均衡和新能源优先分别侧重资源负载与新能源供给，贪心调度依据当前时刻的单步物理代价决策，滚动优化通过有限时间窗口求解调度方案。各方法采用相同的任务输入、数据中心配置、候选范围和硬约束筛选规则，以保证实验公平性。此外，除整体调度性能依据主要结果评价外，各资源利用率、权重敏感性、阈值敏感性和消融实验均采用5组随机种子进行重复运行，并报告均值和标准差。

评价指标 评价指标包括式（14）定义的综合调度目标J，以及购电成本、碳排放、区域峰值电网负荷、资源利用率、任务迁移规模和新能源消纳率等物理指标，并结合迁移数据量来分析网络开销。其中，综合目标由上述六项目标加权构成，在综合考虑经济性、低碳性、新能源消纳及区域供电安全的前提下，本文初始设置基准权重$\mathbf{w}=(1.00,0.35,0.25,0.22,0.18,0.30)$，作为多目标调度的折中基准，并在后续通过权重敏感性实验验证其适用性。

3.2　综合调度分析

为评价不同调度方法的综合调度能力，本文在相同任务流、数据中心资源和调度约束下，将ROSE-GAT与六种方法进行对比实验，主要结果如表1所示。

由表1可知，ROSE-GAT的综合目标J为149.042，低于除贪心调度外的其他方法，贪心调度为148.286，略低于ROSE-GAT；从购电成本和碳排放来看，ROSE-GAT分别为7473.16元和7040.99kg，相比无调度分别降低5.34%和6.28%，均取得较低水平；从区域峰值负荷来看，ROSE-GAT为1082.68kW，相比无调度降低5.84%；轮询调度虽进一步降低峰值负荷，但其综合目标较高，新能源优先方法则出现峰值负荷升高的情况。

表1　综合调度性能结果

方法	综合目标J	电费/元	碳排放/kg	区域峰值负荷/kW
无调度	151.281	7894.85	7512.60	1149.77
轮询调度	168.266	7688.65	7287.49	**1007.68**
负载均衡	162.486	8028.78	7684.98	1100.94
新能源优先	155.718	7554.43	7060.69	1251.69
贪心调度	**148.286**	7639.94	7214.23	1149.77
滚动优化	158.238	7647.06	7274.40	1148.45
ROSE-GAT	149.042	**7473.16**	**7040.99**	1082.68

综合来看，ROSE-GAT在综合目标、经济性、低碳性和区域负荷控制之间取得了较好的平衡，虽然综合目标并非所有方法中最低，但能够避免单一目标优化带来的指标偏移，体现出多目标协同调度的优势。

3.3　多数据中心调度分析

为进一步分析不同调度策略在多数据中心场景下的任务部署及迁移行为，本文从任务分配与资源利用、跨区域迁移与网络开销两个方面进行分析。由于本文采用仿真网络模型，网络侧主要通过迁移数据量、迁移网络能耗、往返时延和迁移时间表征网络开销。其中，图3以调度策略为横轴、任务数量为纵轴，展示7种调度策略在8个数据中心上的任务分配结果；图4以时间槽为横轴、跨区域迁移任务数为纵轴，展示6种调度策略在24个时间槽内的跨区域迁移变化。图3和表2用于分析任务在不同数据中心的分布及资源利用情况，图4和表3则进一步分析跨区域迁移的时序特征及相关网络开销。

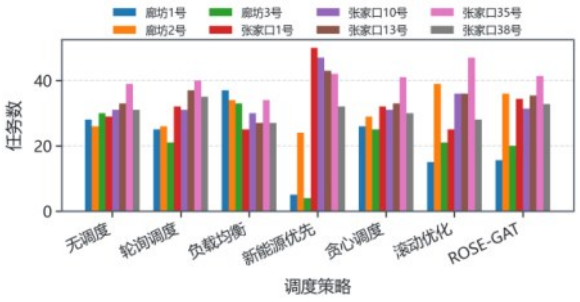

图3　各数据中心任务分配情况

表2　各方法多维资源利用率

方法	综合算力利用率/%	CPU利用率/%	GPU利用率/%	内存利用率/%
无调度	24.56±15.17	20.40±12.29	11.34±7.93	30.48±18.42
轮询调度	24.95±16.56	20.76±13.42	11.63±8.28	31.08±20.02
负载均衡	22.50±9.65	18.53±7.86	9.90±6.82	27.38±12.71
新能源优先	**27.22±23.50**	**22.78±19.95**	**13.04±13.09**	**34.34±30.98**
贪心调度	25.01±17.16	20.81±14.12	11.65±9.03	31.15±21.38
滚动优化	24.32±19.99	20.24±16.88	11.44±10.82	30.35±26.06
ROSE-GAT	25.57±18.02	21.32±15.03	12.04±9.91	32.00±23.10

由图3可以看出，不同调度策略的任务分配存在明显差异，其中新能源优先策略表现出较强的任务集中性，部分任务明显向张家口1号数据中心集中。结合表2可以发现，新能源优先策略下的综合算力、CPU、GPU和内存利用率均高于ROSE-GAT方法，但标准差也明显更大，说明资源利用波动较强，与图3所反映的任务分配不均相一致。相比之下，ROSE-GAT的任务分配综合考虑资源、能源及迁移条件，在资源利用与任务分布之间取得较好的平衡。

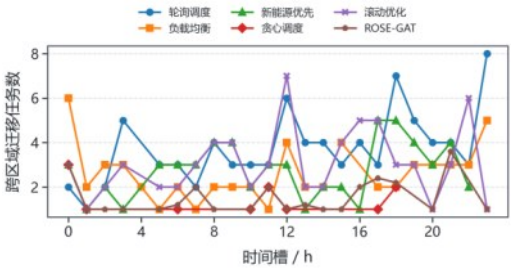

图4　跨区域迁移任务数变化曲线

从图4可以看出，不同策略的迁移行为具有明显的时序波动，轮询调度在部分时间槽出现较高迁移峰值，而ROSE-GAT整体迁移规模相对较低，仅在部分任务集中到达时段出现阶段性波动。结合表3进一步表明，ROSE-GAT平均跨区域迁移25.2次、迁移数据量234.16GB，表明其能够在任务部署收益与迁移开销之间进行权衡。

表3　ROSE-GAT的跨区域迁移与网络开销统计

指标	结果（均值±标准差）	单位
跨区域迁移次数	25.2±2.8	次
跨区域迁移数据量	234.16±25.10	GB
迁移网络能耗	1.83±0.16	kWh
平均跨区域往返时延	18.00±0.00	ms
平均跨区域迁移时间	7.457±0.280	s
CPU、GPU、内存高负载计数	0	次

综合上述实验结果，ROSE-GAT并非单纯追求资源利用率最大化或依靠频繁跨区域迁移获得调度收益，而是根据数据中心状态和任务需求进行差异化部署。在8个数据中心、24个时间槽的统计范围内，CPU、GPU和内存利用率超过0.90的高负载事件均为0，表明当前实验场景下各类资源均满足容量安全约束。同时，ROSE-GAT将跨区域迁移次数、迁移数据量及相关网络开销控制在较低水平，实现了任务分配、资源利用与迁移开销之间的平衡。

3.4　目标权重敏感性分析

式（12）中的权重向量$\mathbf{w}$决定各调度目标在综合目标中的相对重要程度。为分析权重选择对调度结果的影响，本文以3.1小节中权重配置作为基准，并设置经济性导向(1.00,0.20,0.15,0.15,0.10,0.20)、低碳导向(1.00,0.80,0.20,0.15,0.10,0.35)、新能源消纳导向(1.00,0.25,0.90,0.15,0.10,0.25)和负荷峰值导向(1.00,0.30,0.20,0.20,0.30,0.80)四种权重配置。在相同任务流和约束条件下进行5组随机种子实验，比较不同导向下的主要物理指标和迁移规模。结果如表4所示。

表4　不同目标权重组合下的调度结果

权重配置	购电成本/元	碳排放/kg	弃用新能源/kWh	区域峰值/kW	迁移数据量/GB
基准权重	7473.16±14.00	7040.99±13.68	129.80±23.02	1082.68±24.38	234.16±25.10
经济性	**7412.28±48.83**	**6970.75±55.84**	161.56±57.25	1101.77±68.08	384.41±28.53
低碳型	7428.62±45.06	6981.94±51.84	233.26±80.77	1089.92±80.50	420.57±43.29
新能源型	7417.33±19.07	6976.36±14.65	179.93±39.61	1145.59±33.77	347.30±19.47
负荷峰值	7516.68±33.45	7103.25±39.40	**19.76±18.34**	**1037.33±23.11**	**198.52±53.34**

由表4可以看出，不同权重配置会影响各调度目标之间的权衡。经济性导向下购电成本和碳排放分别降至7412.28元和6970.75kg，但迁移数据量增至384.41GB；低碳导向下碳排放为6981.94kg，但迁移数据量进一步增加至420.57GB。负荷峰值导向下区域峰值降至1037.33kW，弃用新能源降至

19.76kWh，但购电成本和碳排放分别升至7516.68元和7103.25kg。总体来看，不同权重配置体现了调度目标间的权衡，针对特定目标的优化可能牺牲其他指标。基准权重在经济性、低碳性、新能源利用、负荷控制和迁移开销之间取得相对均衡，并可根据实际需求进行进一步调整。

3.5　迁移收益阈值分析

迁移收益阈值用于筛选预测收益不足的迁移动作，其取值会影响任务迁移规模及整体调度效果。为验证阈值设置的合理性，本节在其余实验条件保持一致的情况下，设置多组不同阈值进行对比实验。其中，图5以迁移收益阈值为横轴，以综合目标和迁移数据量为纵轴，用于展示阈值变化对整体调度效果和迁移规模的影响；表5则列出具有代表性的阈值对应结果。

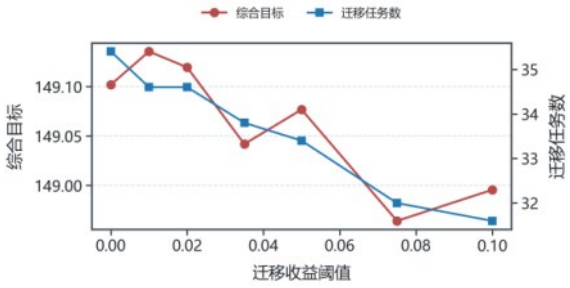

图5　迁移收益阈值对综合目标与迁移规模的影响

表5　不同迁移收益阈值下的调度结果

阈值	综合目标J	购电成本/元	碳排放/kg	弃用新能源/kWh	迁移数据量/GB
0.000	149.102±0.73	**7460.21±20.42**	**7028.73±23.63**	**117.43±21.53**	296.02±33.21
0.035	149.042±0.67	7473.16±14.00	7040.99±13.68	129.80±23.02	**234.16±25.10**
0.075	**148.964±0.58**	7481.53±6.33	7051.09±4.75	129.92±23.52	265.43±23.86
0.100	148.995±0.56	7482.09±6.24	7052.02±3.78	129.92±23.52	265.69±23.57

结合图5和表5可知，随着阈值提高，综合目标J和迁移数据量均存在一定波动，并未随阈值单调变化。综合目标在阈值0.075时最低，为148.964，较基准阈值0.035的149.042略有下降；当阈值提高至0.10时，综合目标小幅回升至148.995；阈值由0提高至0.035时，迁移数据量发生大幅度下降，说明提高阈值能够减少低收益迁移。因此，在本文测试范围内，阈值0.075对应的综合目标最低，但相较于阈值0.035，其综合目标仅降低0.078，迁移数据量则由234.16 GB增至265.43 GB。考虑到综合目标改善幅度有限，而较低阈值能够保留更多潜在迁移机会，本文选取0.035作为基准阈值。该设置体现的是综合目标与迁移规模之间的折中，而非综合目标的全局最优选择。

3.6　消融实验

本节为进一步验证文中所提两个核心模块的作用，分别设置“无边感知候选图”和“无滚动优化监督”两组消融实验。其中，无边感知候选图去除候选数据中心之间的关系边；无滚动优化监督采用当前物理综合代价替代条件长期代价作为训练标签。为保证实验公平性，三种方法采用相同的任务流、数据中心配置、调度约束和5组随机种子，最终调度结果取5次实验的均值及标准差。表6给出了三种方法在购电成本、碳排放、区域峰值负荷、新能源消纳率方面的结果。

表6　消融实验结果

方法	购电成本/元	碳排放/kg	区域峰值负荷/kW	新能源消纳率/%
无边感知候选图	7476.16±17.46	7041.40±17.44	1096.62±30.89	99.44±0.13
无滚动优化监督	7530.78±11.01	7098.13±10.20	1149.77±20.13	99.30±0.03
ROSE-GAT	**7473.16±14.00**	**7040.99±13.68**	**1082.68±24.38**	**99.55±0.08**

由表6可见，完整ROSE-GAT在所列指标上整体优于两种消融版本，说明边感知候选图和滚动优化监督结合有助于改善整体调度性能。去除边感知候选图后，各项指标均出现一定程度退化，表明候选数据中心之间的区域、能源和网络关联信息能够帮助模型更准确地评价候选部署位置，改善任务部署后的资源与能源协调；去除滚动优化监督后，调度性能下降更为明显，表明仅依据当前物理综合代价难以反映任务部署对后续资源竞争、能源利用和区域负荷的影响，条件长期代价能够为候选评价提

供有效的前瞻性信息。总体而言，两个模块分别从候选关系建模和长期影响学习两个方面提升了调度决策能力，二者结合能够进一步改善跨区域算电协同调度性能。

4 结束语

针对跨区域多数据中心调度中候选数据中心关联关系难以描述以及当前状态决策难以反映长期影响的问题，本文提出一种计及节点关联与长期影响的跨区域算电协同调度方法ROSE-GAT。该方法通过边感知候选图表征候选数据中心间的算电与网络关联，并利用滚动优化生成包含未来资源竞争和能源状态变化的条件长期代价，实现跨区域任务协同调度。实验结果表明，相较无调度策略，ROSE-GAT使购电成本、碳排放和区域峰值负荷分别降低5.34%、6.28%和5.84%，新能源消纳率达到99.55%，表明所提方法能够有效改善经济性、低碳性和新能源利用水平。尽管本文方法取得了一定效果，仍存在进一步研究空间：（1）当前实验仅包含2个区域和8个数据中心，后续需进一步扩展数据中心规模、负载水平及新能源渗透场景，以验证方法在不同运行条件下的泛化能力；（2）当前假设任务在部署后不再发生二次迁移，后续将可进一步考虑资源竞争、任务优先级调整及节点故障等动态因素，深入研究任务二次迁移的影响。

参考文献：

[1] 李逸博, 李小平, 王爽, 等. 面向算力网络的智慧调度综述[J]. 自动化学报, 2024, 50(6): 1086-1103.
LI Y B, LI X P, WANG S, et al. Survey on wise scheduling in computing power network[J]. Acta Automatica Sinica, 2024, 50 (6): 1086-1103.

[2] 李明睿, 朱介北, 俞露杰, 等. 实现新能源最大利用的多数据中心自适应负荷调度算法[J]. 中国电机工程学报, 2025, 45(6): 2071-2084.
LI M R, ZHU J B, YU L J, et al. Adaptive spatio-temporal tasks scheduling algorithm in regional interconnected data centers[J]. Proceedings of the Chinese Society of Electrical Engineering, 2025, 45(6): 2071-2084.

[3] 李远征, 龙信鑫, 周纯杰, 等. 高比例新能源电网-分布式数据中心集群协同优化运行研究[J]. 中国科学: 技术科学, 2024, 54(1): 119-135.
LI Y Z, LONG X X, ZHOU C J, et al. Coordinated operations of highly renewable power systems and distributed data centers[J]. Scientia Sinica Technologica, 2024, 54(1): 119-135.

[4] 向梓旸, 黄淳驿, 李康平, 等. 考虑负载时空转移特性的数据中心集群算电协同优化调度[J]. 电力信息与通信技术, 2026, 24 (3): 33-46.
XIANG Z Y, HUANG C Y, LI K P, et al. Computing-power Synergistic Scheduling of Internet Data Centre Clusters Considering Spatio-temporal Load Transfer Characteristics[J]. Electric Power Information and Communication Technology, 2026, 24(3): 33-46.

[5] WENG Q, XIAO W, YU Y, et al. MLaaS in the wild: Workload analysis and scheduling in large-scale heterogeneous GPU clusters [C]//19th USENIX Symposium on Networked Systems Design and Implementation. Berkeley: USENIX Association, 2022: 945-960.

[6] VERMA A, PEDROSA L, KORUPOLU M, et al. Large-scale cluster management at Google with Borg[C]//Proceedings of the tenth european conference on computer systems. New York: ACM, 2015: 1-17.

[7] HINDMAN B, KONWINSKI A, ZAHARIA M, et al. Mesos: A platform for fine-grained resource sharing in the data center[C]// Proceedings of the 8th USENIX Symposium on Networked Systems Design and Implementation. Berkeley: USENIX Association, 2011: 295-308.

[8] DELIMITROU C, KOZYRAKIS C. Quasar: Resource-efficient and qos-aware cluster management[J]. ACM Sigplan Notices, 2014, 49(4): 127-144.

[9] YUAN H, BI J, ZHOU M C. Temporal task scheduling of multiple delay-constrained applications in green hybrid cloud[J]. IEEE Transactions on Services Computing, 2018, 14(5): 1558-1570.

[10] GOIRI Í, LE K, HAQUE M E, et al. Greenslot: scheduling energy consumption in green datacenters[C]//Proceedings of 2011 International Conference for High Performance Computing, Networking, Storage and Analysis. 2011: 1-11.

[11] QURESHI A, WEBER R, BALAKRISHNAN H, et al. Cutting the electric bill for internet-scale systems[C]//Proceedings of the ACM SIGCOMM 2009 conference on Data communication. New York: ACM, 2009: 123-134.

[12] 方和平, 刘曙光, 冉泳屹, 等. 基于深度强化学习的多数据中心一体化调度优化[J]. 计算机应用, 2023, 43(6): 1884-1892.
FANG H, LIU S, RAN Y, et al. Integrated scheduling optimization of multiple data centers based on deep reinforcement learning[J]. Journal of Computer Applications, 2023, 43(6): 1884-1892.

[13] 胡亚辉, 王越嶙, 张宸康, 等. 基于DDPG强化学习的多集群算力资源调度算法[J]. 通信学报, 2025, 46(11): 147-161.
HU Y H, WANG Y L, ZHANG C K, et al. Multi-cluster computing power resource scheduling algorithm based on DDPG reinforcement learning[J]. Journal on Communications, 2025, 46(11): 147-161.

[14] FAN J, YAN R, HE Y, et al. Stochastic optimization of combined energy and computation task scheduling strategies of hybrid system with multi-energy storage system and data center[J]. Renew-

able Energy, 2025, 242: 122466.

[15] FAN W, FAN Y, LIU P, et al. Distributionally robust optimization scheduling model for electric power and computing power coordination considering spatiotemporal response[J]. Applied Energy, 2025, 402: 126895.

[16] SHAPIRO A, DENTCHEVA D, RUSZCZYNSKI A. Lectures on stochastic programming: modeling and theory[M].3rd ed. Philadelphia: Society for Industrial and Applied Mathematics, 2021.

[17] BEN-TAL A, EL GHAOUI L, NEMIROVSKI A. Robust optimization[M].Princeton, NJ: Princeton university press, 2009.

[18] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks[C]//International Conference on Learning Representations. ICLR, 2018.

[19] SIMONOVSKY M, KOMODAKIS N. Dynamic edge-conditioned filters in convolutional neural networks on graphs[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2017: 29-38.

[20] GILMER J, SCHOENHOLZ S S, RILEY P F, et al. Neural message passing for quantum chemistry[C]//International conference on machine learning. PMLR, 2017: 1263-1272.

[21] GASSE M, CHÉTELAT D, FERRONI N, et al. Exact combinatorial optimization with graph convolutional neural networks[C]// Advances in Neural Information Processing Systems. 2019, 32: 15580-15592.

[22] HAMILTON W, YING Z, LESKOVEC J. Inductive representation learning on large graphs[J]. Advances in neural information processing systems, 2017, 30: 1024-1034.

[23] KIPF T N, WELLING M. Semi-supervised classification with graph convolutional networks[C]//International Conference on Learning Representations. ICLR, 2017.

[24] MAYNE D Q, RAWLINGS J B, RAO C V, et al. Constrained model predictive control: Stability and optimality[J]. Automatica, 2000, 36(6): 789-814.

[25] RAWLINGS J B, MAYNE D Q, DIEHL M. Model predictive control: theory, computation, and design[M]. 2nd ed. Nob Hill Publishing, 2017.

[26] BERTSEKAS D P. Dynamic programming and optimal control [M]. Belmont, MA: Athena Scientific, 1995.

[27] BENGIO Y, LODI A, PROUVOST A. Machine learning for combinatorial optimization: a methodological tour d'horizon[J]. European Journal of Operational Research, 2021, 290(2): 405-421.

[28] BRUNA J, ZAREMBA W, SZLAM A, et al. Spectral networks and locally connected networks on graphs[C]//International Conference on Learning Representations. ICLR, 2014.

[29] XU K, HU W, LESKOVEC J, et al. How powerful are graph neural networks?[C]//International Conference on Learning Representations. ICLR, 2019.

[30] 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.

[31] REISS C, TUMANOV A, GANGER G R, et al. Heterogeneity and dynamicity of clouds at scale: Google trace analysis[C]//Proceedings of the third ACM symposium on cloud computing. 2012: 1-13.

[32] LU C, YE K, XU G, et al. Imbalance in the cloud: An analysis on Alibaba cluster trace[C]//2017 IEEE International Conference on Big Data. Piscataway: IEEE, 2017: 2884-2892.