

## 融合射频能量采集的协同节能计算迁移研究

汤蓓<sup>1</sup>, 王倩<sup>1</sup>, 陈思光<sup>1,2</sup>

(1. 南京邮电大学物联网学院, 江苏 南京 210003; 2. 南京邮电大学江苏省宽带无线通信和物联网重点实验室, 江苏 南京 210003)

**摘要:** 为适应垂直市场差异化能源需求, 保障物联网设备的高效可持续性运行, 研究了一种融合射频能量采集的协同节能计算迁移机制。具体地, 基于对计算迁移决策、上行带宽资源分配、下行带宽资源分配及基站功率分割的联合优化考量, 构建了一个最小化系统总能耗的优化问题。为有效求解该优化问题, 融合惩罚函数的概念设计了新的评价指标, 并提出了一种基于自适应粒子群优化的协同节能计算迁移算法。该算法构造了动态变化的惯性权重和线性调节的惩罚因子, 可在迭代搜索过程中实时变更粒子群落的空间分布密度, 以生成可容忍惩罚下的最优计算迁移策略; 进一步地, 为避免粒子越过探索范围, 引入了速度边界限制, 可降低无效解的产生概率, 提升搜索有效性。最后, 仿真结果表明所提算法能够实现较高的收敛效率及求解精度, 且与其他常见基准方案相比, 完成任务处理的系统总能耗可分别降低 34.09%、14.72%和 6.86%。

**关键词:** 计算迁移; 能量采集; 资源分配; 功率分割

**中图分类号:** TP393

**文献标志码:** A

**doi:** 10.11959/j.issn.2096-3750.2023.00311

## Radio frequency energy harvesting-combined collaborative energy-saving computation offloading mechanism

TANG Bei<sup>1</sup>, WANG Qian<sup>1</sup>, CHEN Siguang<sup>1,2</sup>

1. School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

2. Jiangsu Key Lab of Broadband Wireless Communication and Internet of Things,  
Nanjing University of Posts and Telecommunications, Nanjing 210003, China

**Abstract:** In order to fit the differentiated energy demands in vertical markets and ensure that internet of things (IoT) devices can hold an efficient and sustainable operation mode, a radio frequency energy harvesting-combined collaborative energy-saving computation offloading mechanism was studied. Specifically, a system energy consumption minimization problem was formulated under the joint optimization consideration of computation offloading decision, uplink bandwidth resource allocation, downlink bandwidth resource allocation and base station power splitting. Meanwhile, by combining the concept of penalty function, a new evaluation index was introduced, and then an adaptive particle swarm optimization-based collaborative energy saving computation offloading (APSO-CESCO) algorithm was proposed to solve the problem. The proposed algorithm constructed dynamic inertia weight and linearly adjusted penalty factor, which could alternate the spatial distribution density of the particle community in real-time during the iterative search process, and the optimal computation offloading policy with tolerable punishment could be well-generated. Furthermore, to prevent particles from exceeding exploration range, the velocity boundary was introduced which could also reduce the generation probability of invalid solutions and improve the actual exploration effectiveness. Finally, the simulation results show that

收稿日期: 2022-07-11; 修回日期: 2022-11-12

通信作者: 陈思光, sgchen@njupt.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61971235); 中国博士后科学基金资助项目 (No.2018M630590); 江苏省博士后科研资助计划 (No.2021K501C); 江苏省“333 高层次人才培养工程”资助项目; 南京邮电大学“1311 人才计划”资助项目

**Foundation Items:** The National Natural Science Foundation of China (No.61971235), The China Postdoctoral Science Foundation (No.2018M630590), The Jiangsu Planned Projects for Postdoctoral Research Funds (No.2021K501C), The “333 High-level Talents Training Project” of Jiangsu Province, The “1311 Talents Plan” of NJUPT

the proposed algorithm can achieve higher convergence efficiency and solution accuracy, and compared with other common benchmark schemes, the system energy consumption can be reduced by 34.09%, 14.72%, and 6.86%, respectively.

**Key words:** computation offloading, energy harvesting, resource allocation, power splitting

## 0 引言

得益于 5G 赋能新时代的发展,融合人工智能技术<sup>[1]</sup>的智能物联网为各行业带来了广阔发展机遇,可推动智能安防<sup>[2]</sup>、智慧城市<sup>[3]</sup>和智能家居<sup>[4]</sup>等领域产品升级,建立多层次商业体系。但该新型发展模式往往会使网络使用频率不断上升,引发用户数据的爆炸式增长,导致物联网设备的能量衰减代价与多元化的终端用户需求较难匹配。为提升系统能效比,建设绿色节能体系架构,雾计算这一灵活便捷的计算模式被广泛运用<sup>[5-7]</sup>,该模式可高效耦合不同的设备接口,以快速分析物联网应用的交互数据,特别地,基于无线感知技术<sup>[8]</sup>和计算迁移技术<sup>[9]</sup>,部署在边缘侧的物理服务器能够有效整合环境可用资源,并对无线传输链路资源进行分割调度,以处理部分能耗较高的用户计算任务,实现良好的边端协作<sup>[10-11]</sup>。

考虑物联网设备资源需求的多样化,如何避免迁移策略选择的盲目性成为新的研究热点<sup>[12-13]</sup>。例如,在异构 5G 网络架构场景下,文献[14]基于差异化可用计算资源、无线信道传输状态及终端用户时延标准,构造了一个混合整数非线性能耗最小化问题,并以迭代求解思想输出最优计算迁移决策及功率分配策略。进一步地,Chen 等<sup>[15]</sup>引入了更复杂的优化变量设计,即带宽资源分配、任务数据迁移占比、设备计算能力和传输功率等,并提出了一种改进的块坐标下降算法来最小化时延和能耗的加权成本。出于相同的优化目标,文献[16]规划了一个多站点移动边缘计算场景下的非凸加权成本最小化问题,并提出了一个分解算法来快速有效地生成最大容忍时延和最大可用计算资源共同作用下的最优迁移决策、服务配置方案及资源分配策略。而 Li 等<sup>[17]</sup>对任务传输速率又加以限制,并研究了一种多服务器协同计算迁移机制,所设计的求解算法融合了凸优化和交替优化的思想,可获得最小终端用户能量消耗。类似地,文献[18]基于动态电压调节技术变更雾节点计算能力,并提出了一个交替最小化算法来求解能耗最低策略。文献[19]构建了一个垂直异构移动边缘计算场景下的能耗最小化问题,并将该非凸问题划分为多个子问题,以有

效求解最优计算迁移决策和上行/下行带宽资源分配。虽然上述研究方案能以较优策略降低终端数据处理能耗,并在一定程度上提升系统能源利用效率,但伴随着数据网联动性建设进程的商业化推广,物联网设备的电池损耗开销极大,而定期更换该元件是难以容忍且较为艰巨的。

因此,为降低检测或替换电池寿命耗尽感知节点所需的运营成本,并确保物联网设备能够充分地利用周围能源,能量采集技术<sup>[20]</sup>被引入其中。当接入设备的主电源电量匮乏且难以得到持续化供电时,该技术可以从各种非传统能量中获取电能来延长系统化进程的协同运作生命周期<sup>[21]</sup>。例如,考虑无线自组织网络场景面临的能量耗尽问题,文献[22]规划了一个融合能量采集技术的平均利润最大化问题,并提出了一种基于李雅普诺夫理念的迁移算法来求解近似最优的资源分配策略和采集时间占比。类似地,文献[23]在采用李雅普诺夫优化架构的基础上,对所构建的时延容忍约束条件下的能耗目标函数进行凸逼近操作,并反复迭代,以此来优化迁移占比、CPU 频率、任务传输功率及能量采集的时隙分割占比等变量,可实现最小化所有设备能耗之和的目标。而 Li 等<sup>[24]</sup>则着手于最小化发射功率,基于交替方向乘法求解的优化变量取值,采用分布式的思想逐次执行凸逼近操作,可进一步提高功率求解精度,以更好地适应绿色化无线供电网络。文献[25]构造了两个独立式的实体,其中雾节点主要负责计算资源的共享,而雾接入点处则采用按时隙划分的线性能量采集模型,可降低任务平均处理时延,并有效维持能源系统的稳定性,提升其网络生命周期。基于相同的能量采集架构,文献[26-27]利用凸优化理论分别实现了多用户场景下剩余能量最大及消耗能量最小的优化目标。不同的是,Zhou 等<sup>[28]</sup>研究了一种基于非线性能量采集的部分计算迁移机制,通过联合优化迁移时间、采集时间和本地计算频率等实现处理效率最大化。综上可知,融合能量采集技术的计算迁移机制可灵活地从无线电信号中获取能量,以增强感知节点的自供能特性,并降低设备的电池损耗代价,保障系统的可持续性运作能力。然而,上述研

究方案主要通过固定单位时间内的节点采集能力，或者采用线性/非线性能量采集模式对任务迁移时间和能量采集时间进行时隙划分，均未考虑设备之间的型号差异性。并且，这类模式会将系统周期设定为一估计值，往往会引发用户接收反馈结果的等待时延误差。

针对上述弊端，本文基于分离式能量采集架构，提出了一种融合射频能量采集的协同节能计算迁移机制，主要贡献如下。

基于对计算迁移决策、上行带宽资源占比、下行带宽资源占比及宏基站发射功率分割占比的联合优化考量，构建了一个最小化处理所有任务所需系统总能耗的优化问题。同时，为表征不同设备可采集能量的上限值，融合考虑了非线性能量采集模式，可依据电路调节参数及饱和状态下的功率门限值来有效地调节目标函数的倾斜程度。

针对上述优化问题，提出了一种基于自适应粒子群优化的协同节能计算迁移（APSO-CESCO, adaptive particle swarm optimization-based collaborative energy saving computation offloading）算法。该算法引入动态惯性权重的思想，以更好地引导粒子探索解空间，提升策略求解精度。同时融合惩罚放大系数的概念，逐次对惩罚因子进行线性调节，可进一步改善求精或求泛的结果预测效果。特别地，在探索过程中设计了飞行速度上限，能够将超出范围的解空间约束到边界值，避免偏移过大。

大量的仿真实验表明，所提算法总是能够以较快的速度收敛至某一固定值，且与传统的粒子群算法相比，迁移策略的求解精确度可提升 7.36%。进一步地，随着任务数据请求压力的增加，该算法始终可以获得最低能耗值，具有良好的性能优势。

## 1 系统模型

### 1.1 网络模型

本文构建了一个融合射频能量采集的雾计算迁移模型，如图 1 所示。该网络模型由用户层和雾节点层两部分构成，主要包含用户设备、雾节点和宏基站 3 类实体。各层之间的联系及具体功能阐述如下。

第一层是用户层，该层共部署  $M$  个物联网设备，且每隔一个固定时间间隔  $T$ ，都会随机地向雾节点层发送计算任务请求。由于物联网设备原始可存储能量有限，较难稳定维持长周期内或无源场景下的便携化、可接续化及智能化等应用服务，因此，这些设备

会协同感知区域内资源，将部分请求任务迁移至雾节点进行处理，并从宏基站射频信号中捕捉并采集能量，来降低设备电池的替换成本，提高能源使用效率。

第二层是雾节点层，该层由宏基站和雾节点两部分组成，宏基站主要负责保障物联网设备与雾节点之间的不间断通信，并提供持续可用性供电服务，使得接入的物联网设备可以灵活便捷地存储额外能量，以提升自供电能力，延长使用年限并降低能量消耗；而雾节点则可以感知自身通信覆盖范围内的物联网设备，并判断其所产生的计算任务是否需要迁移处理，依据能耗最小化迁移策略，为相关设备分配一定的带宽资源，当计算任务处理完毕时，将处理结果发送给物联网设备。特别地，融合无线传输能够同时承载信息和能量的属性<sup>[29]</sup>，本文定义上述能量采集过程和信息反馈过程是同步进行的，且物联网设备可以对宏基站的发射功率进行分割处理，实现反馈结果信息的解码转发，并将采集到的能量存储至电池单元。




图 1 融合射频能量采集的雾计算迁移模型

### 1.2 计算模型

根据上述网络模型描述，可以将物联网设备  $i \in \{1, 2, \dots, M\}$  向雾节点层发送的任务请求信息定义为  $(D_i, T_i^{\max}, P_i^{\max})$ 。其中， $D_i$  表示物联网设备  $i$  待处理的业务数据大小； $T_i^{\max}$  为物联网设备  $i$  的最大容忍时延； $P_i^{\max}$  表示在饱和状态下设备  $i$  的功率门限值，通常由设备生产厂商及设备型号所确定。当雾节点层接收到该请求信息时，将以最小化总能耗为目标，生成相应的迁移策略  $(\alpha_i, \beta_i, \gamma_i, \mu_i)$ 。其中， $\alpha_i$  表示物联网设备  $i$  的任务计算迁移决策， $\alpha_i = 1$  表示该任务在本地设备进行处理， $\alpha_i = 0$  表示将该任务迁移至雾节点进行处理； $\beta_i$  表示雾节点分配给物联网设备  $i$  的上行带宽资源占比； $\gamma_i$  表示设备  $i$  的下行信道带宽资源占比； $\mu_i$  为设备  $i$  对基站发射功率的分割占比。本文假设在物联网设备接收基站射频信号的过程中，无线传输信道不会受其他频段干扰信号的影响，能够提供稳定的通信链路传输服务。并且在时间间隔  $T$  内，宏基站与物联网设备之间的

信道状态信息保持不变。结合上述描述，可将本地计算模型和雾节点计算模型分别定义如下。

1) 本地计算模型

对于本地计算而言，用户层请求的计算任务将由物联网设备进行处理。由于每个设备之间的计算能力有所差异，因此本文定义物联网设备*i*的本地计算能力为 $f_i^l$ ，所产生的本地计算时延为

$$T_i^l = \frac{\alpha_i D_i}{f_i^l} \quad (1)$$

对应地，处理完物联网设备*i*请求任务的本地计算能耗表示为

$$E_i^l = P_i^l T_i^l = \frac{\alpha_i P_i^l D_i}{f_i^l} \quad (2)$$

其中， $P_i^l$ 为设备*i*的本地计算功率。

2) 雾节点计算模型

物联网设备*i*选择将任务迁移至雾节点进行处理时，通常会选取宏基站作为中继转发节点，实现雾节点与终端设备间的信息传递过程，且宏基站与雾节点之间的通信开销可忽略不计，因此在雾节点层处理设备任务的总能耗主要由上行传输能耗、雾节点计算能耗和下行传输能耗3个部分构成。

首先，将设备*i*的上行传输速率表示为

$$R_i^u = \beta_i B^u \text{lb} \left( 1 + \frac{P_i^u |h_i^u|^2}{\lambda \sigma_i^u} \right) \quad (3)$$

其中， $B^u$ 表示上行信道带宽资源大小， $P_i^u$ 表示物联网设备*i*的传输功率， $h_i^u$ 表示设备*i*发送计算任务时的上行信道增益， $\sigma_i^u$ 表示上行信道的背景高斯白噪声的功率谱密度。考虑实际调制和编码策略的影响，引入固定常数项 $\lambda$ 表征信道容量差距，且 $\lambda \geq 1$ 。

根据该上行传输速率的描述，可以将物联网设备*i*的上行传输时延和传输能耗分别表示为

$$T_i^u = \frac{(1-\alpha_i)D_i}{R_i^u} \quad (4)$$

$$E_i^u = P_i^u T_i^u \quad (5)$$

接着，雾节点会对接收到的设备*i*的计算任务进行处理，与本地计算模型相类似，可以将雾节点计算时延表示为

$$T_i^f = \frac{(1-\alpha_i)D_i}{f_i} \quad (6)$$

其中， $f_i$ 为雾节点的计算能力大小，且 $f_i > f_i^l$ 。

而雾节点计算能耗可表示为

$$E_i^f = P_i^f T_i^f = \frac{(1-\alpha_i)P_i^f D_i}{f_i} \quad (7)$$

其中， $P_i^f$ 为雾节点的计算功率。

最后，基于宏基站发出的射频信号，物联网设备可以利用内置的功率分割器对宏基站的发射功率进行分解，分别用于信息解码转发和射频能量采集。在此，将设备*i*所在信道上的传输信号定义为

$$y_i^d = h_i^d s_i^d + n_i^d \quad (8)$$

其中， $s_i^d$ 为下行链路传输信号，所对应的数学期望满足 $E(|s_i^d|^2) = \mu_i P_s$ ， $n_i^d$ 为高斯白噪声，方差为 $\sigma_i^d$ ， $P_s$ 表示宏基站的发射功率。

相应地，依据香农定理，可以将信息解码转发过程中物联网设备*i*对应的下行传输速率表示为

$$R_i^d = \gamma_i B^d \text{lb}(1 + \text{SNR}(y_i^d)) = \gamma_i B^d \text{lb} \left( 1 + \frac{\mu_i P_s |h_i^d|^2}{\lambda \sigma_i^d} \right) \quad (9)$$

其中， $B^d$ 表示下行信道带宽资源大小， $h_i^d$ 表示物联网设备*i*接收反馈数据时的下行信道增益， $\sigma_i^d$ 表示环境噪声的功率谱密度。

因此，接收解码信息的下行传输时延可以表示为

$$T_i^d = \frac{(1-\alpha_i)D_i'}{R_i^d} \quad (10)$$

其中， $D_i'$ 为雾节点层反馈给设备*i*的计算任务处理结果的数据大小。

而对应的下行传输能耗可以表示为

$$E_i^d = P_s T_i^d = \frac{(1-\alpha_i)P_s D_i'}{\gamma_i B^d \text{lb} \left( 1 + \frac{\mu_i P_s |h_i^d|^2}{\lambda \sigma_i^d} \right)} \quad (11)$$

特别地，在射频能量采集过程中，为了更好地体现功率与能量转换之间的逻辑关系，本文基于设备所处信道状态及不确定性能量需求，构造了一种非线性能量采集模型，并将物联网设备*i*采集的能量大小定义为

$$E_i^{\text{har}} = \frac{P_i^{\text{max}} T_i^d}{1 + \exp(-a h_i^d (1 - \mu_i) P_s + ab)} \quad (12)$$

其中， $a$ 和 $b$ 为控制能量采集模块的相关参数，可以有效地调目标能耗函数的倾斜程度。

综合上述内容描述，可以表示出完成物联网设备*i*任务处理的系统总能耗为

$$E_i = E_i^l + E_i^u + E_i^f + E_i^d - E_i^{\text{har}} \quad (13)$$

## 2 优化问题描述

通常情况下，平衡能量获取和资源消耗是雾计算迁移场景下的主要目标。因此，本文基于无线链路传输特性，构建了一个系统总能耗最小的优化问题，旨在联合优化计算迁移决策  $\alpha_i$ 、上行带宽资源占比  $\beta_i$ 、下行带宽资源占比  $\gamma_i$  和基站发射功率分割占比  $\mu_i$ ，从而提升系统整体的能量使用效率。所构建的优化问题 P1 为

$$\text{P1} \quad \min_{\alpha_i, \beta_i, \gamma_i, \mu_i} \sum_{i=1}^M E_i \quad (14)$$

$$\text{s.t.} \quad T_i^l + T_i^u + T_i^f + T_i^d \leq T_i^{\max} \quad (14a)$$

$$0 \leq \sum_{i=1}^M \beta_i \leq 1 \quad (14b)$$

$$0 \leq \sum_{i=1}^M \gamma_i \leq 1 \quad (14c)$$

$$0 \leq \mu_i \leq 1 \quad (14d)$$

$$\alpha_i \in \{0, 1\}, \forall i \in \{1, 2, \dots, M\} \quad (14e)$$

在所定义的优化问题中，目标函数式(14)为最小化处理完所有物联网设备计算任务的系统总能耗。约束条件式(14a)表示完成物联网设备  $i$  计算任务的总时间不能超过其自身最大容忍时延；约束条件式(14b)和式(14c)分别表示分配给物联网设备的上行带宽资源和下行带宽资源不能超过信道带宽总资源；约束条件式(14d)表示对基站发射功率的分割占比，其中  $\mu_i P_s$  用于信息解码转发，其余部分用于射频能量采集；约束条件式(14e)表示物联网设备  $i$  任务的计算迁移决策，取值为 0 或 1，分别表示迁移处理和本地处理。本文假设在时间间隔  $T$  内，每个物联网设备只请求一个待处理计算任务。

通过对上述混合整数非线性规划问题的分析，可以发现，约束条件式(14a)~式(14d)为不等式约束条件，约束条件式(14e)为仅含等式约束条件。为了更好地求解系统能耗最小值，本文引入外罚函数的思想，对不满足约束条件的策略赋予较大的惩罚项，以保障迭代点向最优有效可行域逼近，具体操作如下。

首先，将目标函数式(14)定义为  $q(\alpha_i, \beta_i, \gamma_i, \mu_i)$ ；接着，对于仅含等式约束条件而言，由于迁移决策只能为 0 或 1，本文构造了如下惩罚项

$$\rho_1 = \delta \sum_{i=1}^M |\alpha_i(1 - \alpha_i)|^\varphi \quad (15)$$

其中， $\delta$  为惩罚因子，由于本文目标是求取系统总

能耗最小，因此需要设置  $\delta > 0$ ， $\eta \geq 1$ ；类似地，对于其他不等式约束条件而言，分别构造以下惩罚函数

$$\rho_2 = \delta \sum_{i=1}^M |\min(0, T_i^{\max} - T_i^l - T_i^u - T_i^f - T_i^d)|^\varphi \quad (16)$$

$$\rho_3 = \delta (|\min(0, \sum_{i=1}^M \beta_i)|^\varphi + |\min(0, 1 - \sum_{i=1}^M \beta_i)|^\varphi) \quad (17)$$

$$\rho_4 = \delta (|\min(0, \sum_{i=1}^M \gamma_i)|^\varphi + |\min(0, 1 - \sum_{i=1}^M \gamma_i)|^\varphi) \quad (18)$$

$$\rho_5 = \delta \left( \sum_{i=1}^M (|\min(0, \mu_i)|^\varphi + |\min(0, 1 - \mu_i)|^\varphi) \right) \quad (19)$$

其中， $\varphi \geq 1$ 。

最后，原始优化问题能够被映射为最小化系统总能耗与惩罚项之和，所对应的优化问题 P2 可以表述为

$$\text{P2} \quad \min_{\alpha_i, \beta_i, \gamma_i, \mu_i} q(\alpha_i, \beta_i, \gamma_i, \mu_i) + \sum_{j=1}^5 \rho_j \quad (20)$$

## 3 基于自适应粒子群优化的协同节能计算迁移算法

通过对优化问题 P2 的分析，可以发现该优化问题属于混合整数非线性无约束规划问题，难以有效利用传统的梯度下降等方法求解离散解空间，因此，本文提出了一种基于自适应粒子群优化的协同节能计算迁移 (APSO-CESCO) 算法。针对传统粒子群易过早陷入局部最优解的局限性，该算法引入动态惯性权重的思想，协调迭代点在全局搜索与局部搜索之间的平衡性。此外，为克服单一惩罚因子对迭代搜索效果的影响，该算法融合惩罚放大系数，以确保可控容忍范围内的全局计算迁移策略更优，所涉及的评价指标及策略探索过程分别表述如下。

### 3.1 适应度函数的定义

由于本文的优化目标为求取  $M$  个物联网设备各自对应的最优计算迁移决策、上行带宽资源占比、下行带宽资源占比和基站发射功率分割占比，因此可以定义粒子群落的目标搜索空间维数大小为  $4M$ ，假设粒子群落由  $K$  个粒子构成，由于粒子之间存在信息共享行为，因此各个粒子都会受其邻居粒子的影响进行自我学习，并针对性地调整速度和位置，以协同改进整体搜索效率，生成更优计算迁移策略，下面以粒子  $k$  为例来简要描述该过程，其中  $k \in \{1, 2, \dots, K\}$ 。

该粒子首先被随机编码为一个  $4M$  维的向量, 表示为

$$X_k^0 = (x_{k1}^0, x_{k2}^0, \dots, x_{k4M}^0) = (\alpha_{k1}^0, \alpha_{k2}^0, \dots, \alpha_{kM}^0, \beta_{k1}^0, \beta_{k2}^0, \dots, \beta_{kM}^0, \gamma_{k1}^0, \gamma_{k2}^0, \dots, \gamma_{kM}^0, \mu_{k1}^0, \mu_{k2}^0, \dots, \mu_{kM}^0) \quad (21)$$

特别地, 上述目标求解变量的初始值需满足约束条件式(14a)~式(14e)。

接着, 可以将粒子  $k$  的初始飞行速度定义为

$$V_k^0 = (v_{k1}^0, v_{k2}^0, \dots, v_{k4M}^0) \quad (22)$$

考虑上述优化变量均位于  $0 \sim 1$ , 该初始飞行速度被设定为  $[0, 1]$  之间的随机数, 并根据式(23)进行速度更新。

$$v_{km}^{n+1} = \omega^n v_{km}^n + c_1 r_1 (\text{pbest}_{km}^n - x_{km}^n) + c_2 r_2 (\text{gbest}_{K_m}^n - x_{km}^n) = \omega^n v_{km}^n + c_1 r_1 \Delta \text{pbest}_{km}^n + c_2 r_2 \Delta \text{gbest}_{K_m}^n \quad (23)$$

其中,  $m$  表示第  $m$  维向量, 且  $m \in \{1, 2, \dots, 4M\}$ ;  $n$  表示第  $n$  次迭代, 且  $n \geq 0$ ;  $\omega^n$  为第  $n$  次迭代的惯性权重, 表示个体粒子对先前搜索动作的信任程度;  $c_1$  和  $c_2$  分别为个体学习因子和群落学习因子, 表示下一搜索动作采纳个体学习经验和邻居共享经验的权重比;  $r_1$  和  $r_2$  为  $0 \sim 1$  内符合均匀分布的随机概率;  $\text{pbest}_{km}^n$  表示粒子  $k$  在第  $n$  次迭代搜索到的第  $m$  维向量的局部最优位置;  $\text{gbest}_{K_m}^n$  表示整个粒子群落  $K$  在第  $n$  次迭代搜索到的第  $m$  维向量的全局最优位置。这种更新方式使得粒子  $k$  能够在保持自身速度趋势的同时, 依据邻居粒子的协同共享信息更好地搜索解空间, 且更新后的粒子位置可以表示为

$$x_{km}^{n+1} = x_{km}^n + v_{km}^{n+1} \quad (24)$$

最后, 在融合射频能量采集的迁移场景下, 能量消耗是衡量系统效用的主要评价指标。结合上述粒子位置及飞行速度的定义, 本文可以将粒子群算法中的关键要素适应度函数表述为能耗与惩罚函数之和, 具体为

$$f(X) = q(\alpha_i, \beta_i, \gamma_i, \mu_i) + \sum_{j=1}^5 \rho_j \quad (25)$$

其中,  $X$  为由目标求解策略构成的  $4M$  维向量。

### 3.2 最优值的求解

根据上述适应度函数的定义, 可以发现该种评价指标主要包含系统总能耗之和与约束条件惩罚项两个部分。为了更好地求解最小适应度函数值, 即最优计算迁移决策、上行带宽资源占比、下行带宽

占比与基站发射功率分割占比, 本文融合了动态惯性权重和惩罚放大系数的思想, 旨在以更快更平稳的收敛速度获得最优计算迁移策略, 主要描述如下。

针对粒子飞行速度的更新式(23), 可以发现, 惯性权重  $\omega^n$  的取值在一定程度上影响着粒子的实际搜索过程。当  $\omega^n$  的取值较大时, 粒子会更注重全局搜索效果, 极易在算法迭代后期产生震荡现象; 反之, 当  $\omega^n$  的取值较小时, 粒子会更注重自身的局部搜索效果, 虽然收敛速度较快, 但存在陷入局部最优解的不足。因此, 为保障迁移策略的搜索精度, 并提升粒子运动状态的启发性, 本文所提的 APSO-CESCO 算法采用了动态惯性权重的思想, 具体为

$$\omega_n = \omega^{\max} - \frac{n(\omega^{\max} - \omega^{\min})}{N} \quad (26)$$

其中,  $\omega^{\max}$  表示惯性权重的上限值,  $\omega^{\min}$  表示惯性权重的下限值,  $n$  表示当前处于第  $n$  次迭代,  $N$  表示算法的最大迭代次数。为此, 惯性权重的取值大小会随着迭代次数的增加而减小, 可以有效地控制实际收敛性能, 以保障粒子群落越来越逼近理想解。

同时, 为避免粒子位置  $x_{km}^n$  的溢出现象, 本文对粒子飞行速度设定了边界限制, 更新如下

$$v_{km}^{n+1} = \begin{cases} v^{\max}, v_{km}^{n+1} > v^{\max} \\ -v^{\max}, v_{km}^{n+1} < -v^{\max} \\ \omega^n v_{km}^n + c_1 r_1 \Delta \text{pbest}_{km}^n + c_2 r_2 \Delta \text{gbest}_{K_m}^n, |v_{km}^{n+1}| \leq v^{\max} \end{cases} \quad (27)$$

其中,  $v^{\max}$  为粒子飞行速度的上限值。

根据粒子前一时刻的搜索状态  $X_k^n$ , 以最小化适应度函数  $f(X_k)$  为目标, 可以求取下一时刻的局部最优解  $\text{pbest}_k^{n+1}$  和全局最优解  $\text{gbest}_K^{n+1}$ , 具体表示为

$$\text{pbest}_k^{n+1} = \begin{cases} X_k^{n+1}, f(X_k^{n+1}) \leq f(\text{pbest}_k^n) \\ \text{pbest}_k^n, f(X_k^{n+1}) > f(\text{pbest}_k^n) \end{cases} \quad (28)$$

$$\text{gbest}_K^{n+1} = \arg \min \{f(\text{pbest}_k^{n+1})\}, \forall k \in \{1, 2, \dots, K\} \quad (29)$$

紧接着, 可以利用当前探索到的最优解空间, 对粒子的飞行速度及所处位置进行迭代更新, 直至不满足迭代条件, 即到达最大迭代次数  $N$  时, 输出最优计算迁移策略。特别地, 本文引入了惩罚放大系数  $\tau$ , 使得惩罚因子  $\delta$  呈线性增长趋势, 以实现前期迁移决策探索的随机性, 并保障后期资源分配策略输出的精确度及稳定性, 具体表示为

$$\delta^{n+1} = \tau \delta^n \quad (30)$$

为了更好地体现计算迁移策略求解及参数更

新的关联性, 基于自适应粒子群优化的协同节能计算迁移算法见算法1。

**算法1** 基于自适应粒子群优化的协同节能计算迁移算法

**输入:**

请求任务数据大小  $D_i, i \in \{1, 2, \dots, M\}$ ;

任务处理结果的数据大小  $D'_i, i \in \{1, 2, \dots, M\}$ ;

上行信道带宽资源  $B^u$ ;

下行信道带宽资源  $B^d$ ;

宏基站的发射功率  $P_s$

**输出:**

最优策略  $X^*$ ;

最小适应度函数值  $f(X^*)$

**Start**

初始化惯性权重的上限值  $\omega^{\max}$ , 惯性权重的下限值  $\omega^{\min}$  和粒子群落的粒子个数  $K$ ;

初始化惩罚因子  $\delta^0$  和惩罚放大系数  $\tau$ ;

初始化设备数量  $M$ , 最大迭代次数  $N$  和空间维数  $4M$ ;

**for**  $k=1$  **to**  $K$  **do**

随机生成满足约束条件式(14a)~式(14e)的粒子  $k$  的编码位置  $X_k^0$ ;

初始化粒子  $k$  的飞行速度  $V_k^0$ ;

选择  $X_k^0$  作为局部最优位置  $\text{pbest}_k^0$

**end for**

**for**  $n=1$  **to**  $N$  **do**

**for**  $k=1$  **to**  $K$  **do**

根据式(27)更新飞行速度  $V_k^n$  的每个维度;

根据式(24)更新粒子位置  $X_k^n$ ;

**if**  $f(X_k^n) \leq f(\text{pbest}_k^{n-1})$  **then**

$\text{pbest}_k^n = X_k^n$ ;

**else**

$\text{pbest}_k^n = \text{pbest}_k^{n-1}$ ;

**end if**

**end for**

根据式(29)记录当前的全局最优解;

根据式(30)更新惩罚因子  $\delta^n$ ;

**end for**

得到最优策略  $X^*$  和最终的最小适应度函数值  $f(X^*)$

**end**

## 4 仿真结果与分析

本文通过一系列仿真实验来评估所提 APSO-CESCO 算法的有效性, 通过与常见基准方案的对比分析, 验证了所提方案的性能优势。

在仿真实验中, 假设用户层共部署 5 个物联网设备与雾节点层进行任务交互及能量协同感知。相关实验参数设定如下: 物联网设备  $i$  请求的任务数据大小  $D_i$  在 10~100 kB 内随机生成, 本地计算功率  $P_i^u$  和上行传输功率  $P_i^t$  的取值均为 1~5 W, 雾节点层的宏基站发射功率和雾节点计算功率分别为 20 W 和 15 W, 且系统电路饱和状态下的功率门限值  $P_i^{\max}$  在 5~10 W 内随机生成, 本地计算能力  $f_i^l$  在 20~40 kB/s 内随机生成。特别地, 为便于简便计算, 本文定义返回任务结果的数据大小  $D'_i$  为请求任务数据大小  $D_i$  的一半, 且完成任务处理的最大容忍时延  $T_i^{\max}$  为 0.5 s, 雾节点的计算能力  $f_i$  取值为 2 MB/s, 上行信道带宽资源大小  $B^u$  和下行信道带宽资源大小  $B^d$  分别为 25 kB/s 和 15 kB/s, 上行信道增益  $h_i^u$  和下行信道增益  $h_i^d$  分别为  $10^{-5}$  和  $10^{-6}$ , 表信道实际差异参数  $\lambda$  的数值设为 5, 上行/下行信道的高斯白噪声功率谱密度  $\sigma_i^u$  和  $\sigma_i^d$  分别设定为  $10^{-9}$  和  $10^{-10}$ , 调节非线性能量采集模块的相关参数  $a$  和  $b$  分别取值为 10 和 2。

不同种群大小下适应度函数的收敛情况如图 2 所示, 可以看出, 当粒子群落种群大小设定为 2 时, 函数的收敛速度最快, 但所对应的最优取值却远高于其余两种方案, 这是因为两个粒子所处的空间位置较为集中, 缺乏探索多样性; 此外, 当迭代次数达到 115 次时, 种群大小为 3 和 5 这两种情况下的适应度函数曲线首次相交, 且后续均稳定保持收敛状态。为降低运行时间并保障较高求解精确度, 本文选择将粒子群落的种群大小设置为 3。




图2 不同种群大小下适应度函数的收敛情况

不同速度边界限制下适应度函数的收敛情况如图 3 所示，可以看出，为粒子的飞行速度设定不同的上限值，适应度函数的收敛效果差异比较明显。当速度边界值为 0.1 时，部分粒子的搜索范围较为发散，极易掠过最优解空间，使得适应度函数收敛不到最小值；反之，当速度边界限制为 0.005 时，由于搜索空间轨道较为集中，粒子群落趋于初始位置附近搜索，无法跳出局部最优解；而当最大速度取值为 0.015 时，函数曲线分别在 40 次和 105 次迭代呈现收敛趋势，且取值比其余两种方案更小，即收敛效果较好。因此，本文将后续仿真实验中的最大飞行速度设置为 0.015。




图 3 不同速度边界限制下适应度函数的收敛情况

不同惯性权重下适应度函数的收敛情况如图 4 所示，其中“APSO-CESCO”代表本文采用的动态惯性权重。当惯性权重的值设为 0 时，适应度函数取值保持不变，为一恒定值，且该值为初始飞行速度下对应的最小取值，这是因为粒子群落未产生任何演化过程，即粒子未扩散，无法寻求最优解；当惯性权重为 1 时，各个粒子可以在前期探索到较广的空间域，使得适应度函数能够更快速地到达最优解附近，但其迭代后期的搜索效率和收敛精度比较低；相较而言，呈线性递减趋势的动态惯性权重下的函数收敛效果更优，可确保粒子群落在迭代初期实现较大种群覆盖率，并在后期维持高效的局部搜索能力，以更好地生成任务计算迁移策略。

不同惩罚因子下适应度函数的收敛情况如图 5 所示，可以看出，3 种惩罚因子取值下的函数收敛速度基本一致，但收敛到的最终解差别较大。当初始惩罚因子为 0.001 时，由于惩罚项较小，粒子探索的迁移决策方案非最优，导致适应度函数取值较大；反之，若初始惩罚因子取值较大，在算法迭代

初期资源分配策略的随机探索过程中，易引发因不满足约束条件所需的额外惩罚。综上所述，本文将后续仿真实验中初始惩罚因子的取值设定为 0.01。




图 4 不同惯性权重下适应度函数的收敛情况




图 5 不同惩罚因子下适应度函数的收敛情况

基于上述已选择的仿真实验参数，本文进行了 100 次的模拟实验，并将收敛的适应度函数的均值分别与其他 3 种基准方案进行对比分析，以验证所提计算迁移机制在系统总能耗方面的性能优势。其中，“Full local”表示所有物联网设备的计算任务都在设备本身进行处理；“Full offloading”表示所有计算任务都迁移至唯一雾节点进行处理；“PSO”表示基于传统粒子群算法的计算迁移方案<sup>[30]</sup>；“APSO-CESCO”表示的是本文所提计算迁移方案。

任务数据大小对系统总能耗的影响如图 6 所示，可以看出，所有方案下的能量消耗都随着任务数据大小的增加而增加，由于物联网设备的计算能力远远小于雾节点的计算能力，因此全本地处理方案下的总能耗最高，全迁移处理方案次之；再者，传统粒子群方案融合了射频能量采集技术，并对迁移决策、上行/下行带宽资源及宏基站发射功率分割占比实施联合优化，使得系统总能耗得以进一步降

低；但该方案下的搜索精确度较低，易错过更优资源分配策略，而本文引入的惯性权重和惩罚函数思想，可以提高求解精度并获得最低系统能耗。

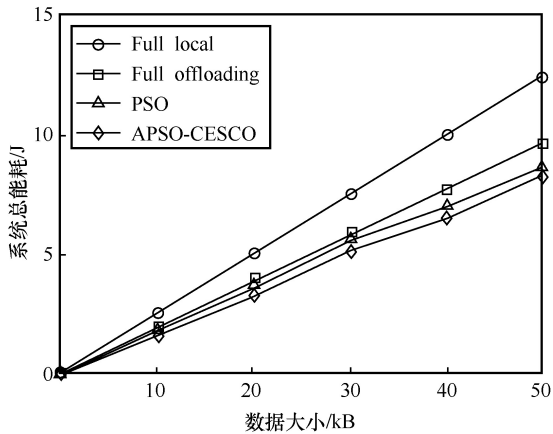


图 6 任务数据大小对系统总能耗的影响

雾节点计算能力对系统总能耗的影响如图 7 所示，可以看出，若雾节点的计算能力较小，则全迁移处理方案下的总能耗最高，这是因为此时降低通信开销也难以弥补计算开销的劣势，但随着节点计算能力的提升，其能耗值可逐步降低，即该劣势能够被有效缓解；同时，由于本地计算能耗只与用户请求数据大小、本地计算功率及本地计算能力息息相关，并不会被变化的雾节点计算能力所影响，因此全本地处理方案下的系统总能耗为一固定常数；此外，本文所提方案较基于固定惯性权重的粒子群优化算法而言，拥有更优的粒子空间探索模式，使得收敛到的平均能耗值更低。

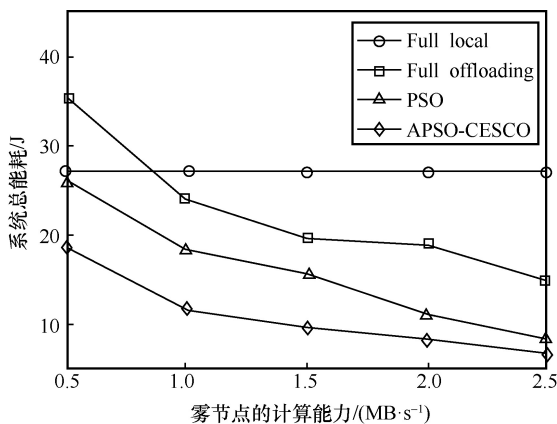


图 7 雾节点计算能力对系统总能耗的影响

综上所述，本文所提 APSO-CESCO 算法在求解融合外罚函数思想的无约束计算迁移策略时，总是能够以较快的收敛速度得出最低适应度函数值，并且在不同任务数据大小及不确定性计算能力等场景下，都

可以高效整合任务请求信息并配置相关资源分配占比，以提升可用资源利用率，降低系统总能耗。

## 5 结束语

为完善节能雾计算架构，建设绿色环保的物联网供电模式，本文研究了一种融合射频能量采集的协同节能计算迁移机制。基于对计算迁移决策、上行/下行带宽资源分配及宏基站发射功率分割的联合优化考量，本文构建了一个最小化系统总能耗的优化问题。同时，融合外罚函数的思想，将原始优化问题转化为新的混合整数非线性无约束规划问题，并提出一种基于自适应粒子群优化的协同节能计算迁移算法来求取最优值。通过融合动态惯性权重、速度边界限制及惩罚放大系数的思想，有效地调节粒子群落飞行范围，并平衡全局搜索及局部搜索的重要性。最后，经过批量性的模拟实验验证，与常见基准方案相比，本文所提方案总是能够获得最低系统总能耗值，且算法的平均收敛效果最优。

## 参考文献：

- [1] BREM A, GIONES F, WERLE M. The AI digital revolution in innovation: a conceptual framework of artificial intelligence technologies for the management of innovation[J]. *IEEE Transactions on Engineering Management*, 2021(99): 1-7.
- [2] KIM H, CHA Y, KIM T, et al. A study on the security threats and privacy policy of intelligent video surveillance system considering 5G network architecture[C]//*Proceedings of 2020 International Conference on Electronics, Information, and Communication (ICEIC)*. Piscataway: IEEE Press, 2020: 1-4.
- [3] ZHOU S H, WEI C F, SONG C F, et al. Short-term traffic flow prediction of the smart city using 5G Internet of vehicles based on edge computing[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022(99): 1-10.
- [4] CHEN M, MIAO Y M, JIAN X, et al. Cognitive-LPWAN: towards intelligent wireless services in hybrid low power wide area networks[J]. *IEEE Transactions on Green Communications and Networking*, 2019, 3(2): 409-417.
- [5] CHEN S G, WANG Z H, ZHANG H J, et al. Fog-based optimized kronecker-supported compression design for industrial IoT[J]. *IEEE Transactions on Sustainable Computing*, 2020, 5(1): 95-106.
- [6] WANG Q, CHEN S G. Latency-minimum offloading decision and resource allocation for fog-enabled internet of things networks[J]. *Transactions on Emerging Telecommunications Technologies*, 2020, 31(12): 1-14.
- [7] SHI J, DU J, WANG J, et al. Deep reinforcement learning-based V2V partial computation offloading in vehicular fog computing[C]//*Proceedings of 2021 IEEE Wireless Communications and Networking Conference (WCNC)*. Piscataway: IEEE Press, 2021: 1-6.
- [8] JIANG Y X, SHUAI Y H, HE X L, et al. An energy-efficient street

- lighting approach based on traffic parameters measured by wireless sensing technology[J]. IEEE Sensors Journal, 2021, 21(17): 19134-19143.
- [9] CHEN S G, ZHU X, ZHANG H J, et al. Efficient privacy preserving data collection and computation offloading for fog-assisted IoT[J]. IEEE Transactions on Sustainable Computing, 2020, 5(4): 526-540.
- [10] CHEN S G, CHEN J M, MIAO Y F, et al. Deep reinforcement learning-based cloud-edge collaborative mobile computation offloading in industrial networks[J]. IEEE Transactions on Signal and Information Processing over Networks, 2022(8): 364-375.
- [11] CHEN S G, TANG B, WANG K. Twin delayed deep deterministic policy gradient-based intelligent computation offloading for IoT[J]. Digital Communications and Networks, 2022, doi.org/10.1016/j.dcan.2022.06.008.
- [12] MUKHERJEE M, KUMAR V, KUMAR S, et al. Computation offloading strategy in heterogeneous fog computing with energy and delay constraints[C]//Proceedings of 2020 IEEE International Conference on Communications (ICC). Piscataway: IEEE Press, 2020: 1-5.
- [13] CHANG Z, LIU L, GUO X, et al. Dynamic resource allocation and computation offloading for IoT fog computing system[J]. IEEE Transactions on Industrial Informatics, 2021, 17(5): 3348-3357.
- [14] LI S L, TAO Y Z, QIN X Q, et al. Energy-aware mobile edge computation offloading for IoT over heterogenous networks[J]. IEEE Access, 2019(7): 13092-13105.
- [15] CHEN X H, CAI Y L, SHI Q J, et al. Efficient resource allocation for relay-assisted computation offloading in mobile-edge computing[J]. IEEE Internet of Things Journal, 2020, 7(3): 2452-2468.
- [16] NGUYEN P D, LE L B. Joint computation offloading, SFC placement, and resource allocation for multi-site MEC systems[C]//Proceedings of 2020 IEEE Wireless Communications and Networking Conference. Piscataway: IEEE Press, 2020: 1-6.
- [17] LI Q, SHAO H Q. Cooperative resource allocation for computation offloading in mobile-edge computing networks[C]//Proceedings of 2021 IEEE Wireless Communications and Networking Conference. Piscataway: IEEE Press, 2021: 1-6.
- [18] CHEN S G, ZHENG Y M, LU W F, et al. Energy-optimal dynamic computation offloading for industrial IoT in fog computing[J]. IEEE Transactions on Green Communications and Networking, 2020, 4(2): 566-576.
- [19] CHEN J, CHANG Z, GUO X J, et al. Resource allocation and computation offloading for multi-access edge computing with fronthaul and backhaul constraints[J]. IEEE Transactions on Vehicular Technology, 2021, 70(8): 8037-8049.
- [20] WANG F, XING H, XU J. Real-time resource allocation for wireless powered multiuser mobile edge computing with energy and task causality[J]. IEEE Transactions on Communications, 2020, 68(11): 7140-7155.
- [21] LIN Z F, WANG F, LIU L C. Computation rate maximization for multiuser mobile edge computing systems with dynamic energy arrivals[C]//Proceedings of 2021 IEEE/CIC International Conference on Communications in China (ICCC). Piscataway: IEEE Press, 2021: 312-317.
- [22] WANG W P, FENG G S, LI B Y, et al. An online computation offloading with energy-harvesting in mobile ad hoc network[C]// Proceedings of 2019 IEEE International Conference on Smart Internet of Things (SmartIoT). Piscataway: IEEE Press, 2019: 22-27.
- [23] LI C L, TANG J H, ZHANG Y, et al. Energy efficient computation offloading for nonorthogonal multiple access assisted mobile edge computing with energy harvesting devices[J]. Computer Networks, 2019(164): 1-12.
- [24] LI H, XIONG K, LU Y, et al. Distributed design of wireless powered fog computing networks with binary computation offloading[J]. IEEE Transactions on Mobile Computing, 2021(99): 1.
- [25] BOZORGCHENANI A, TARCHI D, CORAZZA G E. Computation offloading decision bounds in SWIPT-based fog networks[C]//Proceedings of 2019 IEEE Global Communications Conference. Piscataway: IEEE Press, 2019: 1-6.
- [26] YU Z Y, XU G C, LI Y, et al. Joint offloading and energy harvesting design in multiple time blocks for FDMA based wireless powered MEC[J]. Future Internet, 2021, 13(3): 70.
- [27] YANG Z H, HOU J C, SHIKH-BAHAEI M. Resource allocation in full-duplex mobile-edge computation systems with NOMA and energy harvesting[C]//Proceedings of ICC 2019 - 2019 IEEE International Conference on Communications. Piscataway: IEEE Press, 2019: 1-6.
- [28] ZHOU F H, HU R Q. Computation efficiency maximization in wireless-powered mobile edge computing networks[J]. IEEE Transactions on Wireless Communications, 2020, 19(5): 3170-3184.
- [29] LU P, HUANG K M, SONG C Y, et al. Optimal power splitting of wireless information and power transmission using a novel dual-channel rectenna[J]. IEEE Transactions on Antennas and Propagation, 2022, 70(3): 1846-1856.
- [30] ZHU C, TAO J, PASTOR G, et al. Folo: latency and quality optimized task allocation in vehicular fog computing[J]. IEEE Internet of Things Journal, 2019, 6(3): 4150-4161.

## [作者简介]



汤蓓（1997-），女，南京邮电大学硕士生，主要研究方向为雾/边缘计算、智能物联网。



王倩（1996-），女，南京邮电大学博士生，主要研究方向为雾/边缘计算、智能物联网。



陈思光（1984-），男，博士，南京邮电大学教授，主要研究方向为雾/边缘计算、智能物联网。