doi:10.3772/j.issn.1002 -0470.2026.06.006

基于雾计算的分布式网络优化方法①

彭永倩② 刘 鸿③

(黔南民族职业技术学院大数据与电子商务系 都匀 558022)

摘 要 针对智慧茶园环境中分布式网络面临的高延迟与低能效问题,本文提出一种基于雾计算的分布式网络优化算法。本文建立了综合考虑计算能力、通信带宽与能量消耗的多层级网络模型,提出了一个优化框架,能够高效调度任务并进行计算迁移。在此基础上,设计了融合自适应惯性权重、局部搜索、遗传交叉和约束惩罚机制的混合粒子群优化(hybrid particle swarm optimization,Hybrid-PSO)算法,该算法显著提升了全局搜索能力与解的可行性。实验结果表明,Hybrid-PSO 算法在多目标优化问题上,能够有效减少系统总延迟、能耗和任务完成时间,收敛速度也显著优于传统的粒子群优化(particle swarm optimization,PSO)算法、遗传算法(genetic algorithm,GA)和 PSO-GA 算法。进一步分析表明,计算迁移与能量感知路由策略的引入,不仅优化了负载均衡,还显著延长了网络的寿命。

关键词 雾计算;自适应惯性权重;局部搜索;遗传交叉;约束惩罚机制;改进粒子群算法

随着物联网技术[1-2]的快速发展,全球物联网设备数量已经多达亿万级,而海量数据处理分析需求的不断增长,给资源受限的物联网设备和移动智能终端设备带来巨大的存储、共享和处理等负担[3-4]。尽管传统的云计算方式[5]能够有效处理海量数据,但是在位置感知、移动性支持以及延迟响应等方面存在一定的局限性。基于此,雾计算方式应运而生。作为云计算的延伸,雾计算采用分布式架构设计,将数据、数据处理和应用程序集中在网络边缘的设备中,不仅能够减少数据传输延迟,还能够提高实时响应速度[6-8]。但由于计算任务不断增多,雾计算节点在处理过程中可能会面临大量的资源调度和计算迁移操作[9],使得系统的计算延迟和能量消耗有所增加。

基于此,本文在分布式网络架构下提出一种基于雾计算的分布式网络优化算法。首先,在建立的综合考虑计算能力、通信带宽与能量消耗多层级网络模型基础之上,提出多目标联合优化框架,确保在满足系统计算资源约束的前提下,最小化系统的总延迟与能量消耗。然后,针对优化目标,设计了混合粒子群优化(hybrid particle swarm optimization, Hybrid-PSO)算法,结合自适应惯性权重、局部搜索、遗传交叉和约束惩罚机制,提升解的全局搜索能力和局部收敛精度。最后,以智慧茶园环境中分布式网络面临的高延迟与低能效问题为背景进行了仿真实验。实验结果表明,Hybrid-PSO 算法在多目标优化问题上能够有效减少系统延迟、能耗和运行时间,并且收敛速度较快。

1 相关工作

目前,国内外学者针对雾计算系统架构以及雾计算中的任务优化问题展开了广泛研究并取得了一定成果。文献[10]针对工业生产中基于软件定义网络的雾计算架构大数据处理场景中的独立任务调度问题,提出了基于粒子群的多目标优化任务调度算法。文献[11]提出一种多目标灰狼优化算

① 贵州省高校人文社会科学研究项目(2025RW020)资助。
② 女,1998 年生,硕士,讲师;研究方向:计算机网络与雾计算;E-mail: 18785418275@163.com。
③ 通信作者,E-mail: 1079898617@qq.com。
(收稿日期:2025 -06 -27)

法(multi-objectives grey wolf optimizer, MGWO),引入多目标优化策略,旨在减少云-雾计算中的任务调度延迟和能源消耗。文献[12]构建了一个最小化所有任务完成总能耗的优化问题,并提出基于动量梯度和坐标协同下降的公平性能耗最小化算法用于问题求解。文献[13]提出一种基于元启发式山地瞪羚优化的任务调度方法(metaheuristic mountain gazelle optimization algorithm based task scheduling approach, MMGOA-TSA),以提高下一代物联网-雾-云网络中的生存性。文献[14]提出一种改进的生活选择优化算法(life-choice-based optimization algorithm, ILCO),用于解决雾-云区块链系统中的任务调度问题。文献[15]提出一种结合遗传算法(genetic algorithm, GA)和粒子群优化(particle swarm optimization, PSO)的混合算法,用于优化雾计算环境下的多目标任务调度。文献[16]基于区块链赋能物联网场景,提出一种联合资源分配与控制的智能计算迁移方案,融合深度确定性策略梯度(deep deterministic policy gradient, DDPG)算法思想,通过优化通信、计算资源与迁移决策以最小化任务完成总成本。文献[17]提出一种基于物联网(Internet of Things, IoT)和雾计算的资源管理模型,采用遗传算法与机器学习相结合进行工业4.0环境下的预测性维护。文献[18]通过改进的自适应神经模糊推理系统(adaptive neuro-fuzzy inference system, ANFIS)进行雾-云服务分类,并采用一种融合混沌理论的蚱蜢优化算法(chaotic-based grasshopper, CGOA)与GA的新型元启发式算法进行服务调度。文献[19]将物联网服务请求的均衡建模为一个优化问题,并利用改进的蝙蝠算法(bat algorithm, BA)求解云雾网络负载均衡优化问题。文献[20]提出一种基于遗传算法的资源聚类分配方法,通过融合遗传算法和k-means聚类方法,用于提高物联网应用在分层异构雾计算平台中的资源分配效率。

综上,目前研究主要采用启发式优化算法对雾计算运行问题进行任务优化,但未考虑多源异构任务在雾计算系统上的整体运行特性,且现有研究往往仅针对部分计算任务进行优化。为此,本文提出了一种基于雾计算的分布式网络优化算法,能够精确描述多源异构任务在雾-云环境中的调度与迁移特性。

2 算法实现

本文研究的分布式网络系统整体架构如图1所示。其中感知层部署了多个传感器节点,雾计算层包含若干雾节点,云计算层为远程云平台。任务的调度、计算和传输均在感知层与雾计算层之间完成,云平台仅在特定场景下接管部分计算任务。

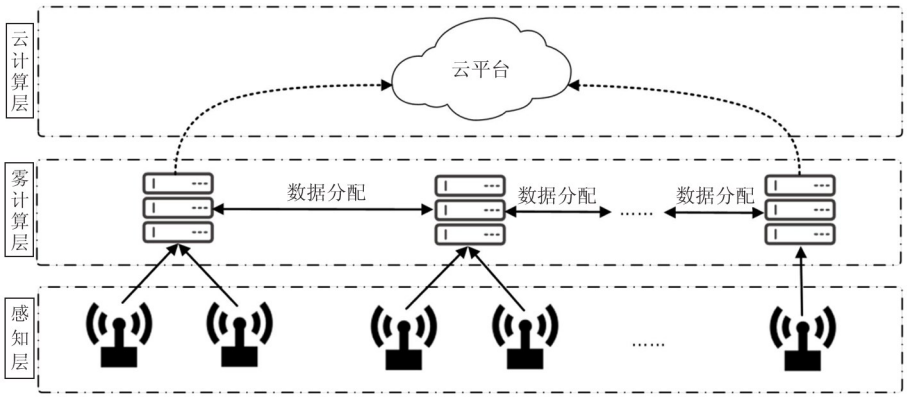

图1 分布式网络系统整体架构

2.1 网络与资源建模

设系统中总共部署了N_s个传感器节点,编号为$i=1,2,\cdots,N_s$,每个传感器节点i具备计算能力$C_s(i)$(单位:CPU cycles·s^{-1}),主要承担环境数据的采集和初步处理,能量消耗为$E_s(i)$,其消耗与数据采集频率和通信活动密切相关。雾计算层包含N_f个雾节点,编号为$j=1,2,\cdots,N_f$,每个雾节点的计算能力为$C_f(j)$(单位:CPU cycles·s^{-1}),带宽为

B_{ij}（单位：Mbps），表示传感器节点 i 与雾节点 j 之间的可用链路带宽。雾节点具备较高的计算和存储能力，能够接收、调度、处理来自感知层的多源异构任务。传感器节点周期性产生待处理任务，记第 i 个节点的任务为 T_i。每个任务 T_i 具有数据量 S_i（单位：Mb）和计算需求 L_i（单位：cycles），分别与任务的大小和复杂度成正比。在任务处理过程中，系统能量消耗主要由如下两部分组成。

（1）计算能耗：当任务被雾节点 j 执行时，其计算能耗记为 $E_{\text{comp}}(i,j)$，通常与任务计算量 L_i 和雾节点的计算能力 $C_{\text{f}}(j)$ 相关；

（2）传输能耗：任务从传感器节点 i 传输至雾节点 j 的能耗为 $E_{\text{send}}(i,j)$，其大小受任务数据量 S_i 和链路带宽 B_{ij} 影响。

任务 T_i 的总能耗 E_i 可表示为

$$E_i = E_{\text{comp}}(i,j) + E_{\text{send}}(i,j) \tag{1}$$

同时，任务的处理延迟包括传输延迟与计算延迟 2 部分。

$$D_{ij} = \frac{S_i}{B_{ij}} + \frac{L_i}{C_{\text{f}}(j)} \tag{2}$$

2.2　问题建模与优化目标

在前述系统模型下，分布式网络中的核心问题是如何在满足资源约束的前提下，不断优化任务调度、计算迁移和路由选择，以最小化系统的总延迟与能量消耗。为此，本文将网络优化问题建模为一个多目标联合优化问题。设 $x_{ij} \in \{0,1\}$ 为任务分配变量，当任务 T_i 被分配至雾节点 j 时，$x_{ij}=1$；反之为 0。约束条件保证每个任务至多被分配到一个雾节点：

$$\sum_{j=1}^{N_{\text{f}}} x_{ij} \leqslant 1,\ \forall i = 1,2,\cdots,N_{\text{s}} \tag{3}$$

任务 T_i 被分配到雾节点 j 后，总延迟由传输延迟和计算延迟组成，表示为 D_{ij}，总能量消耗表示为 E_i。本文采用延迟与能耗加权求和的形式作为优化目标：

$$\min\left(w_1 \sum_{i=1}^{N_{\text{s}}} \sum_{j=1}^{N_{\text{f}}} x_{ij} \cdot D_{ij} + w_2 \sum_{i=1}^{N_{\text{s}}} E_i\right) \tag{4}$$

式中：w_1、w_2 为延迟和能效的权重系数，用于灵活调整不同优化目标的重要性。此外，为保证系统的可行性，多目标联合优化需满足以下资源约束。

（1）雾节点计算能力约束：

$$\sum_{i=1}^{N_{\text{s}}} x_{ij} \cdot L_i \leqslant C_{\text{f}}(j),\ \forall j = 1,2,\cdots,N_{\text{f}} \tag{5}$$

（2）雾节点能量约束（若系统考虑能耗上限）：

$$\sum_{i=1}^{N_{\text{s}}} x_{ij} \leqslant E_{\text{comp}}(i,j) \leqslant E_{\text{f}}(i),\quad \forall i = 1,2,\cdots,N_{\text{f}} \tag{6}$$

（3）带宽约束：

$$\frac{S_i}{B_{ij}} \leqslant D_{\max},\ \forall i,j \tag{7}$$

式中：$E_f(i)$ 为雾节点 j 的可用能量上限，$D_{\max}$ 表示系统对任务传输时延的最大容忍值。

2.3　雾节点任务分配与计算迁移

在分布式雾计算系统中，任务在雾节点间的分配与迁移对系统性能具有关键影响。为实现任务的合理调度与计算负载均衡，本文设计了雾节点选择与计算迁移机制。对于传感器节点 i 产生的任务 T_i，若初始分配的雾节点 j 的负载过高或计算能力不足，则需将任务重新分配至其他资源更合适的雾节点。为表示任务的分配状态，定义迁移变量 $y_{ij} \in \{0,1\}$，用于表示任务 T_i 是否最终分配至雾节点 j，具体如式（8）所示。

$$y_{ij} = \begin{cases} 1, & T_i \to j \\ 0, & T_i \notin j \end{cases} \tag{8}$$

式中：$T_i \to j$ 表示任务 T_i 最终分配至节点 j（包括初始分配或迁移结果）。当目标节点满足以下条件时，允许迁移。

（1）雾节点计算能力充足：

$$\sum_{j=1}^{N_{\text{s}}} (x_{ij} + y_{ij}) L_i \leqslant C_{\text{f}}(j) \tag{9}$$

（2）雾节点的能耗预算允许：

$$\sum_{i=1}^{N_{\text{s}}} x_{ij} \cdot E_{\text{comp}}(i,j) \leqslant E_{\text{f}}(i),\quad \forall i = 1,2,\cdots,N_{\text{f}} \tag{10}$$

为了降低迁移引起的额外通信开销，引入迁移代价函数如式（11）所示。

$$C_{\text{mig}}(i,j) = \beta_1 \cdot \frac{S_i}{B_{ij}} + \beta_2 \cdot \frac{L_i}{C_{\text{f}}(j)} \tag{11}$$

式中：β_1、β_2 为平衡参数。迁移决策的目标是在保证负载均衡的同时，最小化迁移代价。

2.4　能量感知的路由优化

为进一步降低网络能耗与传输时延，本文设计了能量感知的路由优化机制。系统中的每个任务在传输过程中，除直连外，亦可通过多跳转发至目标雾节点。令 P_{ij} 表示传感器节点 i 至雾节点 j 的可行传

输路径集合,每条路径的代价由能量消耗和带宽共同决定:

$$C_{\text{path}}(p) = \sum_{(u,v)\in p}\left(\frac{S_i}{B_{uv}} + \gamma \cdot \frac{1}{E_u^{\text{res}}}\right) \tag{12}$$

式中:$p \in P_{ij}$ 为路径,E_u^{res} 表示节点 u 的剩余能量,γ 为能量惩罚因子。路径选择策略为

$$p^* = \arg\min_{p\in P_{ij}} C_{\text{path}}(p) \tag{13}$$

即选取代价最小的路径作为任务的传输路径。同时,为防止节点能量耗尽,约束各节点的转发能量消耗不超过能量预算:

$$\sum_{\forall u\in p} E_{\text{send}}(p) \leqslant E_u^{\text{budget}} \tag{14}$$

该机制保证了数据传输过程中能量均衡与系统可靠性。

2.5 多目标优化算法

针对 2.2 节建立的多目标优化问题,本文设计一种改进的粒子群优化算法,结合自适应惯性权重、局部搜索、遗传交叉及约束修正机制,以提升任务分配、计算迁移与路由优化的全局搜索能力和局部收敛精度。

首先,为提升粒子在不同阶段的搜索能力,本文采用自适应惯性权重机制,其惯性权重随迭代次数动态调整,形式为

$$w(t) = w_{\max} - \left(\frac{w_{\max} - w_{\min}}{T}\right)\cdot t \tag{15}$$

式中:$w_{\max}$、$w_{\min}$ 分别为惯性权重的最大值和最小值,T 为最大迭代次数,t 为当前迭代轮次。为避免惯性权重取值的随意性,本文在设计自适应惯性权重机制时,参考了经典粒子群优化文献[21 - 23]对收敛性的分析。已有研究表明,$w_{\max}$ 设置在 0.8 ~ 1.0 之间可以增强全局搜索能力,而 $w_{\min}$ 设置在 0.3 ~ 0.4 之间有利于提高局部收敛精度。考虑到雾计算环境中节点异构性较强,过大的权重可能导致解空间搜索震荡,过小的权重则容易陷入局部最优,因此本文采用文献中常用的折中参数 $w_{\max}$ =0.9 和 $w_{\min}$ =0.4。

其次,为进一步提高粒子在邻域内的搜索能力,本文在粒子标准位置更新后,引入了局部搜索策略,通过在当前粒子位置周围进行小范围扰动,获得更优邻域解,有效增强了局部优化能力。为防止粒子陷入局部最优解,本文融合了遗传交叉与变异机制,在粒子群进化过程中,选取部分优秀粒子对位置向量进行交叉与变异操作,从而增强种群多样性,以此提升全局搜索能力。交叉操作可表示为

$$x'_i = \alpha x_i + (1-\alpha)\cdot x_j \tag{16}$$

式中:x_i、x_j 为被交叉的粒子,$\alpha \in (0,1)$ 为交叉系数,变异操作则通过对粒子位置加入微小随机扰动以获取新解。同时,考虑到所建立的优化模型包含多重资源约束,本文采用了基于惩罚函数的约束修正机制,即对违反约束的粒子,向其适应度函数中引入惩罚项:

$$f_{\text{penalized}}(x_i) = f(x_i) + \lambda \cdot penalty(x_i) \tag{17}$$

式中:λ 表示惩罚因子,$penalty(x_i) = \max(0, g(x_i))$ 表示粒子 x_i 违反约束条件的程度。函数 $g(x_i)$ 用于度量约束偏差,其形式可随具体约束类型而变化。例如,当约束条件涉及变量的上下限时,$g(x_i)$ 可定义为该变量与限制值之间的差值,从而量化偏离程度。

最后,引入多个目标函数的评估和权重动态调整来进一步优化粒子的适应度,确保算法能够平衡不同目标的优化。在更新粒子时,除了考虑全局最优解和个体最优解外,还根据每个目标的优先级动态调整目标函数的权重:

$$\begin{aligned} v_i(t+1) = {} & w(t)\cdot v_i(t) + c_1 \cdot rand_1 \cdot (pbest_i - x_i) + \\ & c_2 \cdot rand_2 \cdot (gbest_i - x_i) + \\ & \sum_{k=1}^{M} w_k(t) \cdot \nabla_k f(x_i) \end{aligned} \tag{18}$$

式中:$v_i(t+1)$ 为粒子 i 在 $t+1$ 次迭代时的速度向量,c_1、c_2 为学习因子,$rand_1$ 和 $rand_2$ 为在区间[0,1]内独立生成的随机数或随机向量,$pbest_i$ 为粒子 i 搜索过程中获得的个体最优位置,$gbest_i$ 为当前粒子群获得的全局最优位置,$w_k(t)$ 为目标 k 的动态权重,$\nabla_k f(x_i)$ 为目标函数 f_k 对粒子位置的梯度。

2.6 算法理论分析

所提多目标优化算法的计算复杂度主要由粒子群规模 P 和迭代次数 T 决定,复杂度为

$$O[P \cdot T \cdot (N_s \cdot N_f)] \tag{19}$$

粒子群在惯性、认知和社会成分的共同作用下,具备良好的收敛性。理论上,算法在足够的迭代轮次下能收敛至可行的 Pareto 最优解集。

3　仿真实验与分析

本节在仿真测试过程中,模拟智慧茶园环境下的智能感知与协同计算场景,主要面向茶园温湿光环境监测、病虫害预警及智能管理数据传输任务。通过在茶园区域内布设大量传感器节点获取环境感知数据,并依托分布式雾计算架构构建感知层与雾计算层之间的任务协同模型。在系统中,感知层节点负责周期性上报多源异构任务,雾节点根据任务特性动态进行计算调度、负载均衡与路由优化。

3.1　实验环境与参数设置

为验证所提基于雾计算的分布式网络优化算法的有效性,本节基于 Matlab 平台构建了智慧茶园感知场景的仿真环境。仿真区域设为 500 m × 500 m 的二维平面空间,该区域内随机部署 $N_s = 100$ 个传感器节点及 $N_f = 10$ 个雾节点。传感器节点周期性产生任务并上传至雾节点进行协同处理。

同时,各任务的计算需求 L_i 遵循均匀分布 $U(10^5, 10^6)$ cycle,任务数据量 S_i 服从 $U(100, 500)$ kB 分布。雾节点的计算能力 $C_f^j \in U(1 \times 10^9, 2 \times 10^9)$ /cycle,通信带宽为 $B_{ij} \in U(1, 10)$ Mbps。

算法参数设置如下:粒子群规模 $P = 30$,最大迭代次数 $T = 100$,惯性权重初始值 $w_{\max} = 0.9$,终止值 $w_{\min} = 0.4$,交叉概率为 0.8,变异概率为 0.1,惩罚函数系数 $\lambda = 100$,评价指标如表 1 所示。

表 1　评价指标

编号	评价指标	单位	备注
1	系统总延迟	ms	-
2	系统总能耗	J	-
3	网络寿命	-	第一个节点能量耗尽时的轮数
4	平均任务完成时间	ms	-
5	收敛速度	-	目标函数值达到预设收敛阈值所需的迭代轮次

Matlab 关键节点伪代码如算法 1 所示。

算法 1　关键节点伪代码

```
1. Initialize parameters:
    - Set network size, node count, and positions
    - Generate random task requirements (computation, data size)
    - Initialize bandwidth, fog node compute capacity, energy consumption
2. Define objective function:
    - Minimize total delay and energy consumption:
        Objective = ∑(Delay) + ∑(Energy)
3. Initialize Hybrid-PSO:
    - Set swarm size (P) and max iterations (T)
    - Initialize particles' positions and velocities
    - Set inertia weight, learning factors, and global best
4. Run Hybrid-PSO optimization:
    For each iteration:
        - For each particle:
            - Calculate fitness (objective function)
            - Update personal best and global best
            - Update particle velocity and position
5. Task scheduling and migration:
```

- Assign tasks to fog nodes based on optimization result
- If node overloaded, migrate tasks to lower load nodes

6. Record results and analyze:
   - Record system performance metrics (delay, energy, task completion)
   - Generate comparison with baseline algorithms (PSO, GA)
7. End simulation

3.2 算法收敛性验证

本节通过收敛曲线对所提 Hybrid-PSO 算法的优化性能进行验证,并与标准 PSO[10]、GA[20]以及不包含局部搜索和约束惩罚机制的基本 PSO-GA[15]算法进行对比。每种算法均在相同初始条件下独立运行 20 次,记录其在多目标联合优化问题上的收敛过程,收敛曲线对比如图 2 所示。其中纵坐标表示目标函数值,值越小,表示优化效果越好;横坐标代表每一轮优化迭代次数。

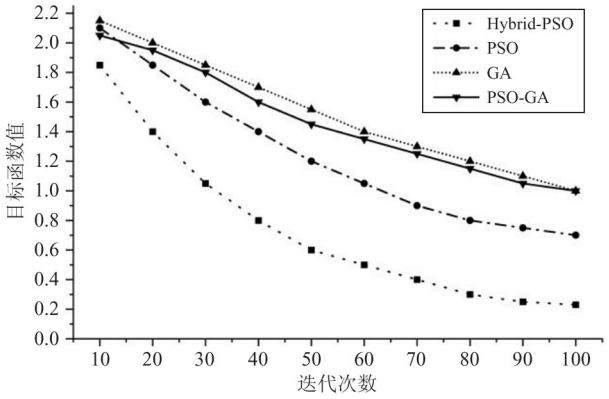

图 2 收敛曲线对比

由图 2 可知,Hybrid-PSO 在收敛速度上具有显著优势,在前 10 轮迭代内就能快速收敛至较优解,且最终的目标函数值最低,展示了其较强的全局搜索能力和稳定性。而 PSO 和 GA 的收敛速度较慢,且目标函数值较高,表明在全局搜索上存在较大的局限性,易陷入局部最优解。而 PSO-GA 虽然结合了 PSO 和 GA 的优点,但由于缺乏局部搜索机制和自适应权重调整,导致收敛速度较慢,且最终的目标函数值相对较高。

3.3 迁移策略有效性分析

为验证计算迁移机制的实际效果,本节分别对启用迁移机制与禁用迁移机制 2 种模式下的系统运行状态进行比较。对比指标包括雾节点负载分布、平均任务完成时间以及系统能耗,实验结果如表 2 和表 3 所示。

表 2 雾节点负载分布

节点编号	启用迁移负载	禁用迁移负载
雾节点 1	0.18	0.35
雾节点 2	0.20	0.45
雾节点 3	0.15	0.40
雾节点 4	0.22	0.38
雾节点 5	0.18	0.42
总计	1.03	2.00

表 3 任务完成时间与能耗对比

指标	启用迁移	禁用迁移
总能耗/J	12.3	14.2
平均完成时间/ms	150	180
任务迁移比例/%	15	0

实验结果表明,启用迁移机制后,系统的负载分布更加均衡,避免了个别节点过载的情况,并显著提高了系统的稳定性和运行效率。具体来说,启用迁移机制后,任务在各雾节点之间的分配更加合理,避免了负载集中在少数节点上的问题,提升了资源利用率。相比之下,禁用迁移机制时,个别节点负载过重,导致了计算延迟和能量消耗的增加,任务的完成时间也显著延长。启用迁移机制后,平均任务完成时间减少了 17.6%,总能耗减少了 13.4%。结果表明,计算迁移机制不仅优化了任务调度,还有效提升了系统的能效,验证了该机制在负载均衡和能效提升方面的作用。

3.4 能量感知的路由优化性能验证

为了验证所设计的能量感知路由机制的有效性,本节比较了在有能耗感知路径选择与无感知情况下节点的能耗分布和系统寿命,实验结果如表 4

和表 5 所示。

表 4 节点剩余能量分布

节点编号	启用能量感知剩余能量	不启用能量感知剩余能量
雾节点 1	0.85	0.60
雾节点 2	0.90	0.58
雾节点 3	0.92	0.55
雾节点 4	0.88	0.57
雾节点 5	0.80	0.53
平均	0.87	0.57

表 5 网络寿命对比

网络寿命	启用能量感知路由	不启用能量感知路由
第 1 个节点失效时间	500	400

实验结果表明,启用能量感知路由策略后,系统的总能耗显著降低,节点的剩余能量明显增加,避免了“热点”节点的过早能量耗尽,从而延长了网络的整体寿命。启用能量感知路由后,网络的第一个节点失效时间延长了 22.3%。此外,节点的剩余能量也得到了有效控制,启用能量感知路由策略后,节点剩余能量的分布更加均匀,而禁用该策略后,部分节点能量消耗过快,导致负载不均和能量浪费。通过实验可知,能量感知路由机制能够有效降低系统的能耗,延长网络寿命,尤其适用于长期运行的物联网应用环境。

3.5 综合性能对比实验

本节从多个维度对比了 Hybrid-PSO 与其他 3 种算法在总延迟、总能耗、平均任务完成时间和收敛速度等方面的性能,实验结果如表 6 所示。

表 6 算法性能对比

算法	总延迟/ms	总能耗/J	平均完成时间/ms	收敛速度/次
Hybrid-PSO	120	12.3	150	30
PSO	150	14.0	180	50
GA	160	13.5	170	45
PSO-GA	155	13.8	175	48

由表 6 可知,Hybrid-PSO 在所有关键指标上均优于其他 3 种算法,特别是在系统总延迟和能耗控制方面,分别减少了 18.7% 和 15.2%。Hybrid-PSO 通过引入自适应惯性权重、局部搜索机制以及遗传交叉策略,显著提高了算法的收敛速度,能够在较少的迭代轮次内快速找到最优解,而其他对比算法,如 PSO 和 GA,则收敛速度较慢且最终的目标函数值较高,显示出它们在全局搜索能力上的不足。此外,Hybrid-PSO 在任务完成时间方面也表现优异,相较于 PSO 和 GA,任务完成时间缩短了 17.6%,这得益于它高效的任务调度和迁移策略。能量消耗方面,Hybrid-PSO 能够在保证任务完成的同时有效减少不必要的能量消耗,明显优于 PSO 和 GA,并且在任务迁移和能量感知路由的帮助下,能够有效避免节点过载,延长网络寿命。最后,Hybrid-PSO 达到收敛条件所需的迭代次数最少,表明其在本实验条件下具有较快的收敛速度;相比之下,PSO 和 GA 所需的收敛迭代次数较多。综上,Hybrid-PSO 在解决智慧茶园等分布式网络优化问题时,展现出了更高的效率和性能,能够在延迟、能耗、任务完成时间和收敛速度等方面提供全方位的优化解决方案。

4 结 论

本文提出的基于雾计算的分布式网络优化算法通过引入多目标优化建模和 Hybrid-PSO 算法,成功解决了智慧茶园等物联网应用中面临的高延迟和低能效问题。通过构建综合考虑计算能力、通信带宽与能量消耗的雾计算网络模型,精确描述了多源异构任务在雾-云环境中的调度与迁移特性,进一步提升了任务调度与计算迁移的效率。基于该模型,本文设计了一个延迟与能效联合优化的多目标建模方法,并通过 Hybrid-PSO 算法有效优化了任务分配、计算迁移和路由选择,显著降低了系统的总延迟和能耗,提升了任务完成效率。仿真结果表明,本文所提出的 Hybrid-PSO 算法在多个实验指标上均优于对比算法,尤其在系统延迟、能效和任务完成时间方面表现突出。同时,计算迁移与能量感知路由机制的引入,不仅优化了负载均衡,还有效延长了网络的使用寿命。这些结果证明了该算法在复杂多目标优

化问题中的优势,并为智慧茶园等物联网应用中的分布式网络优化提供了高效的解决方案。未来的研究可进一步考虑在更复杂的网络环境下进行验证,探讨更具挑战性的多源异构任务调度问题,并结合实际应用场景优化算法参数。

参考文献

[1] 朱茂盛, 王宝晗, 康曼聪, 等. 智能物联网技术赋能算网一体数据库的效能优化[J]. 计算机研究与发展, 2024,61(11):2835 - 2845.

[2] Maqbool R, Saiba M R, Ashfaq S. Emerging industry 4.0 and Internet of Things (IoT) technologies in the Ghanaian construction industry: sustainability, implementation challenges, and benefits[J]. Environmental Science and Pollution Research, 2023,30(13):37076 - 37091.

[3] Baker S, Xiang W. Artificial intelligence of things for smarter healthcare: a survey of advancements, challenges, and opportunities[J]. IEEE Communications Surveys and Tutorials, 2023,25(2):1261 - 1293.

[4] Nilima S I, Bhuyan M K, Kamruzzaman M, et al. Optimizing resource management for IoT devices in constrained environments[J]. Journal of Computer and Communications, 2024,12(8):81 - 98.

[5] 刘芹, 李鹏举, 余纯武. 云计算中属性基数据与权限混合访问控制方案[J]. 计算机工程与应用, 2024, 60(13):276 - 286.

[6] Huaranga-junco E, González-gerpe S, Castillo-cara M, et al. From cloud and fog computing to federated-fog computing: a comparative analysis of computational resources in real-time IoT applications based on semantic interoperability[J]. Future Generation Computer Systems, 2024, 159:134 - 150.

[7] 杨小东, 王秀秀, 李茜茜, 等. 基于区块链和雾计算的去中心化云端数据完整性审计方案[J]. 电子与信息学报, 2023,45(10):3759 - 3766.

[8] Oliveira L T, Bittencourt L F, Genez T A L, et al. Enhancing modular application placement in a hierarchical fog computing: a latency and communication cost-sensitive approach [J]. Computer Communications, 2024, 216:95 - 111.

[9] 张世铂,高洪元,苏雨萌,等. 安全雾计算物联网的联合资源配置方法[J]. 通信学报,2023,44(7):26 - 37.

[10] 朱琳, 沈杨, 周川, 等. 基于粒子群的工业大数据雾计算多目标优化任务调度算法[J]. 南京理工大学学报, 2023,47(1):48 - 55.

[11] Saif F A, Latip R, Hanapi Z M, et al. Multi-objective grey wolf optimizer algorithm for task scheduling in cloud-fog computing[J]. IEEE Access, 2023,11:20635 - 20646.

[12] 陈思光, 尤子慧. 雾辅助物联网中公平节能的计算迁移[J]. 工程科学学报, 2022,44(11):1926 - 1934.

[13] Maashi M, Alabdulkreem E, Maray M, et al. Elevating survivability in next-gen IoT-fog-cloud networks: scheduling optimization with the metaheuristic mountain gazelle algorithm[J]. IEEE Transactions on Consumer Electronics, 2024,70(1):3802 - 3809.

[14] Nguyen B M, Nguyen T, Vu Q H, et al. A novel nature-inspired algorithm for optimal task scheduling in fog-cloud blockchain system[J]. IEEE Internet of Things Journal, 2023,11(2):2043 - 2057.

[15] Saad M, Enam R N, Qureshi R. Optimizing multi-objective task scheduling in fog computing with GA-PSO algorithm for big data application[J]. Frontiers in Big Data, 2024,7:1358486.

[16] 陈思光, 王倩, 张海君, 等. 区块链赋能物联网中联合资源分配与控制的智能计算迁移研究[J]. 计算机学报, 2022,45(3):472 - 484.

[17] Teoh Y K, Gill S S, Parlikad A K. IoT and fog-computing-based predictive maintenance model for effective asset management in Industry 4.0 using machine learning[J]. IEEE Internet of Things Journal, 2023,10(3):2087 - 2094.

[18] Singh S, Vidyarthi D P. An integrated approach of ML-metaheuristics for secure service placement in fog-cloud ecosystem[J]. Internet of Things, 2023,22:100817.

[19] 吴海超,王新民. 物联网低时延云雾混合网络负载均衡策略[J]. 计算机工程与设计,2021,42(12):3323 - 3332.

[20] Abedpour K, Hosseini Shirvani M, Abedpour E. A genetic-based clustering algorithm for efficient resource allocating of IoT applications in layered fog heterogeneous platforms[J]. Cluster Computing, 2024,27(2):1313 - 1331.

[21] Kennedy J, Eberhart R. Particle swarm optimization[C]// Proceedings of International Conference on Neural Networks. Perth, Australia: IEEE, 1995:1942 - 1948.

[22] Shi Y, Eberhart R. A modified particle swarm optimizer[C]// IEEE International Conference on Evolutionary Computation Proceedings. Anchorage, USA: IEEE, 1998:69 - 73.

[23] Clerc M, Kennedy J. The particle swarm-explosion, stability, and convergence in a multidimensional complex space[J]. IEEE Transactions on Evolutionary Computation, 2002,6(1):58 - 73.

A distributed network optimization approach based on fog computing

Peng Yongqian, Liu Hong

(School of Big Data and E-commerce, Qiannan Polytechnic for Nationality, Duyun 558022)

Abstract

This paper addresses the high latency and low energy efficiency issues in distributed networks within smart tea garden environments by proposing an optimization algorithm based on fog computing. A multi-layered network model is developed, considering computational capacity, communication bandwidth, and energy consumption. This model serves as the foundation for an optimization framework that efficiently allocates tasks and manages computational migration. The paper also introduces an hybrid particle swarm optimization (Hybrid-PSO) algorithm, which combines adaptive inertia weights, local search, genetic crossover, and a constraint penalty mechanism. This approach significantly enhances the algorithm's global search ability and solution feasibility. Experimental results show that Hybrid-PSO reduces system latency, energy consumption, and task completion time, outperforming traditional particle swarm optimization (PSO), genetic algorithm (GA), and PSO-GA algorithms in terms of convergence speed. Further analysis indicates that computational migration and energy-aware routing strategies improve load balancing and extend the network's lifetime.

Key words: fog computing, adaptive inertia weights, localized search, genetic crossover, constrained penalty mechanism, improved particle swarm algorithm